


VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY



**FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH
TECHNOLOGIÍ**
ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION
DEPARTMENT OF BIOMEDICAL ENGINEERING

DETEKCE NERVOVÝCH VLÁKEN V BAREVNÝCH OBRAZECH SÍTNICE

DETECTION OF THE RETINAL NERVE FIBRE LAYER

DIPLOMOVÁ PRÁCE
MASTER'S THESIS

AUTOR PRÁCE
AUTHOR

Bc. Martin Kunc

VEDOUCÍ PRÁCE
SUPERVISOR

Ing. Radim Kolář, Ph.D.

BRNO, 2009

LICENČNÍ SMLOUVA POSKYTOVANÁ K VÝKONU PRÁVA UŽÍT ŠKOLNÍ DÍLO

uzavřená mezi smluvními stranami:

1. Pan/paní

Jméno a příjmení: Martin Kunc
Bytem: Hliniště 1, Mikulov, 692 01
Narozen/a (datum a místo): 25. ledna 1985 ve Valticích

(dále jen „autor“)

a

2. Vysoké učení technické v Brně

Fakulta elektrotechniky a komunikačních technologií
se sídlem Údolní 53, Brno, 602 00
jejímž jménem jedná na základě písemného pověření děkanem fakulty:
prof. Ing. Jiří Jan, CSc, předseda rady oboru Biomedicínské a ekologické inženýrství
(dále jen „nabyvatel“)

Čl. 1

Specifikace školního díla

1. Předmětem této smlouvy je vysokoškolská kvalifikační práce (VŠKP):

- ☐ disertační práce
- ☒ diplomová práce
- ☐ bakalářská práce
- ☐ jiná práce, jejíž druh je specifikován jako
(dále jen VŠKP nebo dílo)

Název VŠKP: Detekce nervových vláken v barevných obrazech sítnice

Vedoucí/ školitel VŠKP: Ing. Radim Kolář, Ph.D.

Ústav: Ústav biomedicínského inženýrství

Datum obhajoby VŠKP: _____

VŠKP odevzdal autor nabyvateli*:

- ☒ v tištěné formě – počet exemplářů: 2
- ☒ v elektronické formě – počet exemplářů: 2

2. Autor prohlašuje, že vytvořil samostatnou vlastní tvůrčí činnost dílo shora popsané a specifikované. Autor dále prohlašuje, že při zpracovávání díla se sám nedostal do rozporu s autorským zákonem a předpisy souvisejícími a že je dílo dílem původním.

3. Dílo je chráněno jako dílo dle autorského zákona v platném znění.

4. Autor potvrzuje, že listinná a elektronická verze díla je identická

* hodící se zaškrtněte

Článek 2

Udělení licenčního oprávnění

1. Autor touto smlouvou poskytuje nabyvateli oprávnění (licenci) k výkonu práva uvedené dílo nevýdělečně užít, archivovat a zpřístupnit ke studijním, výukovým a výzkumným účelům včetně pořizování výpisů, opisů a rozmnoženin.
2. Licence je poskytována celosvětově, pro celou dobu trvání autorských a majetkových práv k dílu.
3. Autor souhlasí se zveřejněním díla v databázi přístupné v mezinárodní síti
 - ☒ ihned po uzavření této smlouvy
 - ☐ 1 rok po uzavření této smlouvy
 - ☐ 3 roky po uzavření této smlouvy
 - ☐ 5 let po uzavření této smlouvy
 - ☐ 10 let po uzavření této smlouvy
(z důvodu utajení v něm obsažených informací)
4. Nevýdělečné zveřejňování díla nabyvatelem v souladu s ustanovením § 47b zákona č. 111/ 1998 Sb., v platném znění, nevyžaduje licenci a nabyvatel je k němu povinen a oprávněn ze zákona.

Článek 3

Závěrečná ustanovení

1. Smlouva je sepsána ve třech vyhotoveních s platností originálu, přičemž po jednom vyhotovení obdrží autor a nabyvatel, další vyhotovení je vloženo do VŠKP.
2. Vztahy mezi smluvními stranami vzniklé a neupravené touto smlouvou se řídí autorským zákonem, občanským zákoníkem, vysokoškolským zákonem, zákonem o archivnictví, v platném znění a popř. dalšími právními předpisy.
3. Licenční smlouva byla uzavřena na základě svobodné a pravé vůle smluvních stran, s plným porozuměním jejímu textu i důsledkům, nikoliv v tísní a za nápadně nevýhodných podmínek.
4. Licenční smlouva nabývá platnosti a účinnosti dnem jejího podpisu oběma smluvními stranami.

V Brně dne: 29. května 2009

.....
Nabyvatel

.....
Autor

Abstrakt

Tato práce se zabývá detekcí vrstev nervových vláken na barevných oftalmologických obrazech sítnice. Popisuje se zde, k čemu by se dalo hledání vrstev nervových vláken využít a jak se tato problematika řešila dříve. V práci jsou navrženy metody, které pracují na principu zpracování a vyhodnocování frekvenčních spekter jednotlivých vzorků sítnice. Nejdříve jsou zde popsány metody detekce na uměle vytvořených vzorcích, které nervová vlákna pouze simulují. Poté se již práce soustřeďuje na zpracování reálných obrázků sítnice. Kvůli krevnímu řečišti, které znehodnocuje zpracování u reálných obrázků, jsou všechny zkoumané vzorky vybrány ručně. Kromě samotné detekce vrstvy nervových vláken se práce zabývá i určováním směru jejich šíření.

Abstract

This thesis is deals with the nerve fibre layer in the colour ophthalmology images of retina. The thesis describes how can we use finding of nerve fibre layer and how was it solved in the past. In the thesis are proposed the methods that are based on processing and scoring frequency spectrums of individual sample of retina. At first here are described the methods of detection on the artificial generated samples that just simulate the nerve fibre layer. Then the thesis concentrates on processing of real images of retina. Because of the bloodstream, that depreciates processing at real images, are all surveyed samples are chosen manually. Except detection the nerve fibre layer itself, the thesis also deals with determination of direction their dissemination.

Klíčová slova

vrstva nervových vláken, detekce, sítnice, glaukom, Fourierova transformace, frekvenční spektrum, zpracování obrazu

Keywords

nerve fibre layer, detection, retina, glaukom, Fourier transformation, frequency specrum, image processing

KUNC, M. *Detekce nervových vláken v barevných obrazech sítnice*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2009. 60 s. Vedoucí diplomové práce Ing. Radim Kolář, Ph.D.

Prohlášení

Prohlašuji, že svou diplomovou práci na téma Detekce nervových vláken v barevných obrazech sítnice jsem vypracoval samostatně pod vedením vedoucího diplomové práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené diplomové práce dále prohlašuji, že v souvislosti s vytvořením této diplomové práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení § 152 trestního zákona č. 140/1961 Sb.

V Brně dne 29. května 2009

.....
podpis autora

Poděkování

Děkuji vedoucímu diplomové práce Ing. Radimu Kolářovi, Ph.D. za účinnou metodickou, pedagogickou a odbornou pomoc a další cenné rady při zpracování mé diplomové práce.

V Brně dne 29. května 2009

.....
podpis autora

Obsah

Úvod	7
1 Zrakové ústrojí	8
1.1 Oko a jeho anatomie.....	8
1.2 Jak vidíme	9
2 Glaukom	10
2.1 Co je to glaukom?	10
2.2 Co je glaukomové poškození?.....	10
2.3 Jaké jsou následky glaukomového poškození.....	11
2.4 Ztráta nervových vláken u glaukomu.....	12
3 Metody detekce ztráty nervových vláken na sítnici.....	13
3.1 Měření ztráty nervových vláken na sítnici pomocí optické hustoty.....	13
3.2 Měření proužkové struktury nervových vláken na sítnici	15
3.3 Kvantitativní hodnocení ztráty vrstvy nervových vláken v digitálních barevných oftalmologických obrazech	19
4. Návrh detekce proužkové struktury na umělých vzorcích.....	22
4.1 Dvojměrná Fourierova transformace	22
4.2 Detekce proužkové struktury pomocí frekvenčního spektra.....	23
4.3 Detekce proužkové struktury pomocí spektrogramu	27
5. Návrh detekce nervových vláken na reálných obrázcích.....	31
5.1 Úprava barevných oftalmologických obrazů a vhodný výběr vzorků	31
5.2 Porovnávání výkonů v různých oblastech spekter	33
5.2.1 Vytvoření vhodné masky	36
5.2.2 Porovnání parametrů v různých oblastech spektra.....	38
5.2.3 Korelace a korelační koeficient.....	41
5.2.4 Zhodnocení metody.....	42
5.3 Určování směru proužkování nervových vláken.....	43
5.3.1 Výběr vzorků.....	43
5.3.2 Detekce směru šíření nervových vláken.....	45
5.3.3 Detekce nervových vláken pomocí maximálních výkonů	51
5.3.4 Histogram a jeho úpravy	53
5.3.5 Použití Hammingova okna pro úpravu spektra	54
5.3.6 Testování věrohodnosti	56
Závěr.....	58
Seznam použité literatury	60

Úvod

Jedním z vážných onemocnění oka je glaukom. U glaukomu postupně odumírají nervová vlákna. Důsledkem toho se narušuje spojení mezi okem a mozkiem, které je pro vidění zásadní. Oko stále „vidí“ světlo, protože tyčinky a čípky ještě pracují, ale přenos zrakové informace do mozku je přerušen. To je podstata problému, které je označováno jako „glaukomové poškození“. Ztráta nervových vláken je patrná především na terči zrakového nervu. Protože jsou nervová vlákna průsvitná, jsou jen stěží viditelná. Proto se snímky zhotovují ve světle, u kterého byla odfiltrována červená složka. Poté již jsou nervová vlákna rozeznatelná dobře. Vyznačují se především strukturou připomínající proužkování. V oblasti, kde tato nervová vlákna na sítnici chybí, proužková struktura patrná není. Navíc se zdá být na tmavší, než zbytek sítnice. Lékař tedy může na první pohled konstatovat, zda oko ztrátou nervových vláken trpí či nikoliv. Těžko už ale určí, z kolika procent je oko poškozeno, nebo o kolik se tato oblast od posledního vyšetření zvětšila.

K takovému vyhodnocení by byla potřeba nějaká vhodná metoda, která by automaticky detekovala oblast postiženou ztrátou vrstvy nervových vláken. Lékař by pak mohl sloužit jenom jako kontrolní prvek. Již několik prací se touto problematikou zabývalo. Ve většině případů se ale jednalo pouze o teoretické popisy či matematické postupy. Je tedy potřeba najít vhodné parametry, pomocí kterých by se dalo rozhodnout, zda se jedná o oblast s nervovými vlákny či nikoliv. Několik studií, na hledání takových vhodných parametrů, již existuje. Zabývají se především získáváním vhodných parametrů v prostorové oblasti. Proto se tato práce soustředí na hledání odlišností v oblasti frekvenční.

K tom use využívá typické proužkové struktury, která je pro nervová vlákna typická. Jelikož je na sítnici obsažena ještě poměrně hustá síť krevního řečiště, je problém s detekcí nervových vláken, aniž by se na vyhodnocování krevní řečiště negativně nepodílelo. Problematika s všudypřítomným krevním řečištěm je pro metody automatické detekce vrstvy nervových vláken zásadní. Aby se tomuto složitému problému při hledání vhodných parametrů vyhnulo, vybíraly se vzorky pro další zpracování ručně.

1 Zrakové ústrojí

1.1 Oko a jeho anatomie

Oko je párový orgán zraku a zároveň nejsložitější smyslový orgán lidského těla. Tvoří jej oční koule uložená v tukovém polštáři v očnici, která má tvar pyramidy s vrcholem mířícím dovnitř. Její kostěné stěny tvoří pevnou ochranu pro oko. Otvorem ve vrcholu očnice vstupuje zrakový nerv a v jeho okolí začíná šest okohybných svalů, které se připojují k oční kouli a zajišťují její pohyb. U dospělého zdravého člověka má oční koule průměr asi 24 mm a má téměř dokonale kulovitý tvar.

Oční koule se skládá ze tří vrstev:

a) Zevní bělima – Je tuhá, vazovitá a dokonale neprůhledná. Přední část koule přechází v čirou rohovku.

b) Střední žloutnata – V zadní části oční koule přechází v cévnatku, která zajišťuje výživu oka. Vpředu přechází v duhovku s kruhovou zornicí (pupilou), která reaguje na množství dopadajícího světla. Podle toho mění svůj průměr a reaguje tak na množství světla dopadajícího na sítnici.

c) Vnitřní sítnice – Při lékařských vyšetřeních se pozoruje jako oční pozadí oranžové až červené barvy. Pokrývá asi dvě třetiny vnitřního povrchu oční koule. Obsahuje fotoreceptory (tyčinky a čípky), což jsou světločivné buňky, ve kterých se mění světelný impuls na nervový vzruch. Nervová vlákna sítnice se shromažďují v okolí slepé skvrny ve zrakovém nervu, který světelnou informaci předává prostřednictvím elektrických vzruchů dále zrakovému centru mozku soustředěném do týlního laloku. Zrakový nerv obsahuje 1,2 miliónu axonů, které pokračují z vrstvy nervových vláken sítnice. Vlákna vstupují do zrakového nervu tak, že nejperifernější vlákna jsou uložena na okraji nervu a centrálnější ve střední části.


Přední částí oka je rohovka, která spolu s bělimou tvoří vrchní vrstvu oka. Bělima je z bílé zbarveného vaziva, rohovka z vaziva průhledného. Spolu s oční čočkou umožňuje rohovka lom světelných paprsků jako optická spojka. Na rozdíl od rohovky dokáže oční čočka regulovat intenzitu optického lomu, ke kterému na ní dochází. K této regulaci dochází pomocí stahů a svalů v řasnatém tělísku, na němž je čočka v oku zavěšena.

Funkci optické clony tvoří v oku duhovka. Uvnitř duhovky se nachází kruhový sval. Jeho stahy regulují velikost kruhového otvoru v duhovce panenky. Tak je regulováno množství světla vstupujícího do oka. Prostor mezi rohovkou a duhovkou se nazývá přední komora oční. Ta je vyplněna komorovým mokem produkovaným z úhlu mezi duhovkou a rohovkou.

Vnitřek oka vyplňuje rosolovitá hmota - sklivec. Vnitřní část oka odvrácenou od čočky pokrývá sítnice. V podélné ose oka se nachází na sítnici místo nejvyšší koncentrace světločivných buněk (tyčinek) - tomuto místu nejostřejšího vidění se říká žlutá skvrna. V místě, kde ze sítnice vystupuje svazek nervových vláken tvořící zrakový nerv, světločivé buňky naopak chybí. Pokud optický signál dopadne do tohoto místa, nejsme schopni ho zaznamenat. Toto místo se nazývá slepá skvrna.

Sítnice je vyživována ze sítě drobných cév - cévnatky. Hybnost celého oka zajišťují okohybné svaly. Procvičováním okohybných a akomodačních svalů je zlepšována jednak jejich vzájemná souhra a jednak reflexním působením se podstatně zlepšuje výživa všech tkání. Tím je dosaženo například i zlepšení zaostřování a klesá potřeba dioptrických brýlí nebo čoček.

Přídavnými orgány oka jsou oční víčka, spojivka a slzné ústrojí. Slzy produkované slznou žlázou chrání oko před vysycháním a zajišťují odplavování nečistot, sbírají se ve vnitřním koutku oka a jsou slznými kanálky a slzovodem odváděny do dutiny nosní.



Obr. 1.1: Anatomie oka [15]

1.2 Jak vidíme

Zrak je smysl pro vnímání světelných podnětů (elektromagnetického vlnění) prostřednictvím zrakových pigmentů ve fotoreceptorech sítnice oka. Člověk má zrak uzpůsoben k vnímání pásma vlnových délek asi 400 – 750 nm (modrofialová - červená). Při dostatečném osvětlení vidíme naše okolí plně barevně (fotopicky), což je zajištěno čípkami s různou citlivostí na modré, zelené a červené světlo. Při malé intenzitě světla se aktivují tyčinky, které reagují pouze na intenzitu dopadajícího světla a zajišťují černobílé vidění za šera. Člověk má asi 120 mil. tyčinek a asi 6 mil. čípků, jejichž počet a hustota na jednotku plochy určuje rozlišení našeho vidění. Největší hustota čípků je v okolí žluté skvrny, kde vidíme obraz nejostřeji a oko instinktivně zaměřuje promítání obrazu na sítnici do tohoto bodu. Naopak ve slepé skvrně nejsou žádné světločivné buňky, a tedy obraz promítnutý do tohoto bodu mozek vůbec neregistruje. Elektrické signály, které vznikají ve fotoreceptorech dopadem světelných paprsků, vedou k tvorbě vzruchů. Ty jsou ve zrakové oblasti mozku (neokortexu) nejprve po částech analyzovány (linie, barva, kontrast, pohyb), poté složitým procesem v asociačních oblastech neokortexu vzniká zrakový vjem.

2 Glaukom

2.1 Co je to glaukom?


Termín „glaukom“ zahrnuje široké spektrum nemocí. Bohužel však tento termín není používán jednotně, což může být zavádějící pro ty, kteří se s touto nemocí setkají poprvé. Některé knihy, zejména z kontinentální Evropy, definují glaukom jako skupinu stavů s jedním společným znakem – zvýšeným nitroočním tlakem. Jiné články, především z anglicky mluvících zemí, definují glaukom jako výlučně takové stavy, při kterých dochází k poškození zrakového nervu a ztrátě vidění.

V běžné oftalmologické praxi se ukázalo jako užitečné používat termínu glaukom jak u všech pacientů se zvýšeným nitroočním tlakem (ať už s nebo bez glaukomového poškození), tak u všech pacientů s glaukomovým poškozením (ať už s nebo bez vysokého nitroočního tlaku). [8]


2.2 Co je glaukomové poškození?

Vidění je proces probíhající v několika fázích. Na oko dopadá světlo a sítnice toto světlo převádí na elektrické nervové impulzy, které je mozek schopen zpracovat. Světlo je pohlcováno fotoreceptory na sítnici a informace je předávána gangliovým buňkám sítnice (axonům). Celá tato zraková informace je pak vyslána optickým nervem jako nervový impuls do mozkové části nazývané zraková kůra. Všechny axony gangliových buněk sítnice se sbíhají na terči zrakového nervu (papila zrakového nervu), kde začíná zrakový nerv. Ten spojuje oko s mozkem. Terč zrakového nervu obsahuje pouze axony a žádné fotoreceptory. Malá část sítnice tedy není schopna nic „vidět“ a vytváří fyziologickou slepou skvrnu. Tato malá oblast, na které není zachycena informace, je téměř nepostřehnutelná, protože mozek chybějící část celkového obrazu do jisté míry doplňuje. Slepé skvrny je však možné identifikovat při vyšetření zorného pole.

U glaukomu nervové buňky a nervová vlákna postupně odumírají. V důsledku toho se také narušuje spojení mezi okem a mozkem, které je pro vidění zásadní. Oko stále „vidí“ světlo, protože tyčinky a čípky ještě pracují, ale přenos zrakové informace do mozku je přerušen. To je podstata problému, který je označován jako „glaukomové poškození“. Ztráta nervových vláken je patrná především na terči zrakového nervu.



Obr. 2.1: Směr nervových vláken sítnice. [8]



Obr. 2.2: Nervová vlákna se sbíhají ve zrakový nerv, který oko opouští v místě zvaném terč zrakového nervu. [8]

2.3 Jaké jsou následky glaukomového poškození

V raných stádiích nemoci, kdy odumírají první nervové buňky, zrak mnohdy zůstává překvapivě nedotčený. S postupující chorobou se však v pacientově vidění objevují čím dál závažnější faktory. Oftalmolog je schopen tyto defekty odhalit, ačkoli sám pacient si jich často není vědom. Právě proto je glaukom nebezpečný. Když si pacient ztrátu zorného pole uvědomí, je nemoc již v pokročilém stádiu. Pacient by se neměl nechat „ukolébat“ tím, že zůstává zachována ostrost. Ztráta zorného pole může být značná i při ostrosti 6/6.


Tak jak zdravý člověk nevnímá svou fyziologickou slepou skvrnu, není si pacient s glaukomem vědom narůstajícího počtu a velikosti patologických slepých skvrn (říká se jim také skotomy), které vznikají v důsledku postupné ztráty nervových buněk. Důvodem je schopnost mozku do určité míry nahrazovat chybějící prvky obrazu. Subjektivně je vidění normální, objektivně je však poškozené. S diagnózou glaukomu se tedy nesmí čekat do doby, kdy si pacient začne stěžovat na ztrátu zraku. Včasné odhalení je naprosto zásadní. Pokud je vyšetření oka provedeno dočasně brzy a včas se zahájí nutná léčba, lze obvykle zrakovému poškození a slepotě předejít.

Počet lidí postižených touto nemocí závisí na definici glaukomu, na studované etnické skupině a na průměrném věku populace. Čísla vypovídají, že v průměru jsou glaukomem postižena 3% běžné populace. Pokud se bere úvahu starší populace, je toto číslo značně vyšší. Odhaduje se, že asi 70 miliónů lidí na celém světě má závažné glaukomové poškození, ale jen polovina z nich o této diagnóze ví, a ještě menší procento z nich je odpovídajícím způsobem léčena. Nejméně 7 miliónů pacientů s glaukomem je slepých na obě oči a toto číslo se zvyšuje. [8]

2.4 Ztráta nervových vláken u glaukomu

U glaukomu pomalu odumírají nervové buňky sítnice a její vlákna, což v konečném důsledku vede k přerušení spojení mezi okem a mozkem. Na obr. 2.1 je nákres průběhu nervových vláken. Protože jsou nervová vlákna průsvitná, jsou jen stěží viditelná. Proto byly snímky zhotoveny ve světle, u kterého byla vyfiltrována červená složka. Poté jsou již vlákna rozeznatelná. Obrázek 2.3 představuje nervová vlákna jedince, u kterého je patrný výpadek nervových vláken.

Každé oko je spojeno s mozkem přibližně jedním milionem nervových vláken. Tato vlákna se rozprostírají v nejvnitřnější vrstvě sítnice, sbíhají se na terči zrakového nervu a opouštějí zadní segment oka ve svazcích jako optický nerv. Během života ztratí přirozeným stárnutím některá nervová vlákna dokonce i zdravý člověk. U pacientů trpících glaukomem se však ztráta nervových vláken objevuje rychleji.



Obr 2.3: Ukázka, jak může vypadat výpadek nervových vláken na sítnici.

3 Metody detekce ztráty nervových vláken na sítnici

3.1 Měření ztráty nervových vláken na sítnici pomocí optické hustoty

Nedostatek nervových vláken, neprůhlednost a zrnitý vzhled sítnice jsou základní znaky atrofie zrakového nervu. Pro svou ověřovací studii [1] obdrželi Lundström a Eklundh fundus fotografie z případů rozvíjející se zrakové atrofie zrakového nervu, které byly použity k počítačové densitometrii (měření optické hustoty). Během rozvíjení optické atrofie byl nalezen monotónní vzrůst lokálních změn hustoty. Změna kolísání hustoty hledá základní měřitelné změny v neprůhlednosti vrstvy nervových vláken na sítnici (dále už jen RNFL - retinal nerve fibre layer). Tato metoda je schopna detekovat a vyčíslit rozšíření atrofie RNFL.

Funduskopická vada RNFL informuje o několika chorobách. Takové vady mohou být ohniskové nebo rozptýlené. Ohniskové vady jsou často hlavním následkem náhlých změn v barevnosti hranice mezi atrofickou a normální sítnicí. Na druhou stranu, rozptýlenou atrofii, jak stálého tak i pomalého postupu, je těžké rozpoznat. Lundström a Fríse (1975) popsali dynamický vývoj atrofie nervových vláken v případě s traumatickým poškozením přední zrakové cesty. Během vývoje atrofie byly viděny dva hlavní typy změn: postupné snížení neprůhlednosti RNFL a postupná ztráta příčně pružovaného vzoru. Snižování neprůhlednosti nervových vláken a současně probíhající zvyšování skvrnitosti sítnice se zdá na černobílých fotografiích jako zvyšování změn lokální úrovně šedi.

Změny úrovně šedi na černobílých negativech mohou být zaznamenány pomocí densitometrů jako změny hustoty. Zpráva od Lundströma a Eklundha [1] popisuje metodu, schopnou zaznamenat a vyčíslit tyto změny hustoty. Výsledky, které jsou ve studii prezentované, jsou získány z fundus fotografií sítnice jednoho oka.

Negativy fotografií byly naskenovány pomocí skeneru s velikostí rastru 512 x 768, což odpovídalo řádkovému rozkladu o 21 řádcích/mm. Počet stupňů šedi bylo kolem 40. Jelikož nervové vlákna sítnice byly paprskovitě orientovány kolem optického disku, tak matice byla vzorkována podél kružnic centrovaných stejně jako optický disk. Po této cestě byl podél kružnic vytvořen v digitálním obraze lineární rast. Aby vzorkovací chyby byly co nejmenší, použila se lineární aproximace. Rozlišení podél kruhových oblouků tak zůstalo okolo 21 řádků/mm.

Míra změn hustoty u negativů byla vypočítána následovně:

1. Byl odhadnut střed optického disku v interakci s počítačem. Z každého negativu byly zvoleny kruhové rozklady podél oblouků. Poloměr kruhů byl v rozpětí mezi 2,5 a 4,5 poloměru optického disku
2. Každý oblouk byl reprezentován řadou hodnot $X_j(x_1, x_2, \dots, x_n)$ odpovídající úrovni hustoty podél oblouku. Z těchto hodnot bylo, pomocí odpovídajících absolutních změn mezi sousedními hodnotami hustot podél oblouku, spočítáno Y_j . To reprezentovalo amplitudy hustoty po křivce. $Y_j(y_1, y_2, \dots, y_{n-1}) = (|x_1 - x_2|, |x_2 - x_3|, \dots, |x_{n-1} - x_n|)$.

3. Obrazové elementy, ležící na hlavních přímkách, byly kromě největších y_j odloženy. 5 až 15% bylo necháno mimo tuto cestu.
4. Aritmetický průměr zbylých y_j byl vypočítán pro každý oblouk a použit jako míra lokální změny hustoty.

Ve studii [1] byla vypočítána střední amplituda pro každý oblouk. Byly zde rozpoznány hodnoty z odpovídajících oblouků, reprezentující stupeň změny atrofie. Toto měření se uspořádalo pro každý oblouk. Oftalmoskop během stejné časové periody odhalil postupné snížení nejasnosti RNFL. Snížení neprůhlednosti sítnice koresponduje se zvyšováním lokálního stupně šedi u černobílých negativů. Záznamy zvyšování odchylek hustoty na stejné skupině negativů ukazuje, že použití denzitometrie u fundus fotografií může být použita k detekci změn RNFL.

Studie obrazového zpracování a denzitometrie provedená pomocí počítače byla použita především k snadnějšímu vyčíslení. Průměr svazku nervových vláken v negativěch byl odhadnut na 90 - 240 μm . Proto rozlišení skenování bylo považováno za dostačující k záznamu změn příčně pruhozaného vzoru.

Jelikož paprscité rozložení svazku nervových vláken bylo vyhodnocováno po kružnicích centrováných s optickým diskem, byly použity kružnice o poloměru od 2,5 do 4,5 krát větší než poloměr optického disku. Pokud se použil větší poloměr, tak charakteristická stejnosměrnost zmizela. To odpovídá snižování viditelnost RNFL s rostoucí vzdáleností od optického disku. Účinky jiných struktur, jako např. cévní řečiště na sítnici, byly kvůli velkým změnám hustot eliminovány.

Ostrost negativů je zásadní. Neostře negativy snižují změny mezi šedými stupni a tak ovlivňují změny hustoty. Proto tato metoda byla zkoušena i pro nepatrně rozmazané negativy. Opět byly monotónně hledány zvyšující se změny hustoty, ale byly zkoumány méně než ostré negativy.

Oblast, která by byla podobná geometrii oka, je pomocí fotografie extrémně těžké napodobit. Rozdílnost v centrování může být až 10% velikosti obrázku, navíc nemusí být přesné centrování kružnic do středu optického disku.

3.2 Měření proužkové struktury nervových vláken na sítnici

Metody pro obrazovou analýzu proužkové struktury RNFL z digitalizovaných fundus fotografií byly vyvinuty ke zlepšení detekce a monitorování zhoršujícího se šíření ztráty RNFL. Proužkování bylo měřeno porovnáváním proměnlivosti napříč vysoké prostorové frekvence s proměnlivostí RNFL. Tyto lokálně normalizované hodnoty proužků vynahradí obě široké změny hustoty uvnitř a mezi jednotlivými RNFL fotografiemi. Ve studii Eli Peli [2] bylo použito pět opakovaných měření pro tři oblasti z každého obrazu sítnice. Výsledky měření od pěti pacientů se záznamem ztráty optického pole, mající choroby optického nervu, byly porovnány s pěti normálními a pěti podezřelými oky.

Diagnostické hodnoty, prokazující poškození nervových vláken, mohou být názorně ukázány u několika chorob. Jak je již řečeno, atrofie nervových vláken na sítnici může být buď ohnisková nebo rozptýlená. U rozptýlené atrofie, se kterou je proužkovaný vzor spojený, se zdravé RNFL postupně snižuje, což lze vidět často u glaukomu.

Fundus obrazy a fotografie pro vyhodnocení RNFL atrofie mají těžký úkol. Speciálně pro rozptýlenou atrofii, na kterou byla zaměřena právě tato studie. Ke zlepšení vyhodnocení RNFL fotografií byly navrženy a porovnány různé fotografické techniky. Metody RNFL vyhodnocení využívající zpracování digitálních fotografií se stále zlepšují.

Kvalitativní měření RNFL bylo pokusem o jiné vyšetření. Tamagi [3] našel významný vztah mezi úrovní ztráty optického pole a klasifikovanou atrofií RNFL. Atrofie byla subjektivně odhadnuta pomocí densitometrie z fundus fotografií bez červené složky. Atrofií pozorovanou pomocí densitometrie klasifikoval do čtyř úrovní od normálního RNFL až do úplné atrofie. Ve studii Lundström a Eklundh [1] použili k měření RNFL atrofie pro jednoho pacienta digitalizovanou densitometrii. Pro měření RNFL atrofie využili nestálost měření, definovanou jako absolutní rozdíly mezi sousedními hodnotami hustot podél soustředného oblouku optického disku. Tyto výsledky měření byly vysoce citlivé na kontrast a jasovou změnu mezi obrázky.

Ve studii Eli Peli [2] je tento přístup použití podobného měření obrazového zpracování rozšířený a upravený. Používají se zde hodnoty proměnlivosti, což je lokálně normalizováno ke kompenzaci široké škály hustot mezi fundus fotografiemi, pořízenými v rozdílných časech. Tyto odchylky nastanou ze změn osvětlení, které souvisí s velikostí zornice a lokální změnou hustoty uvnitř každé fotografie. To vše díky uspořádání cév na pozadí a změně barevnosti. Kompenzace je hotová při porovnání změny měření hustoty přes RNFL s hodnotami podél RNFL v rámci stejné fundus plochy.

Lundström a Eklundh [1] uskutečnili měření optické hustoty podél oblouku soustředného do středu optického disku, zatímco měření optické hustoty ve studii Tamagi [3] bylo vzato podél rovných přímk přes svazek nervových vláken. Významné je to, že ačkoliv proužkování nervových vláken na sítnici se rozbíhají v optický disk, vlákna se zřejmě ve 2 až 3 disku sbližují. Průměr z okraje optického disku se tak zdá být o hodně menší než přímý odhad centra nervového svazku. Pokud se stanoví střed (protnutí) RNFL u měření dvou bodů podél dvou odlišných zřetelných pruhů nervových vláken a vypočítá se bod, kde by se dvě přímky protnuly, definuje se tak přesnost této měřicí techniky. Pak se odebírají vzorky řešení, kde se zdají být vlákna skoro paralelní. I proto v navazující studii [2] byly měření provedeny podél proužkových přímk oblouků.


Hodnoty hustoty odpovídající odrazivosti byly vzaty podél přímek, které byly tažené přes RNFL proužky. Jas hodnot byl brán podél každé přímky generující vektor x_i :

$$x_i = (x_{i,1}, x_{i,2}, \dots, x_{i,n}) \quad (1)$$


Množství vektorů bylo pořízeno touto cestou ze souboru paralelních sousedících přímek, oddělených od sebe jedním pixelem X :

$$X = \begin{matrix} & x_{1,1} & x_{1,2} & \dots & x_{1,n} \\ & \cdot & \cdot & \dots & \cdot \\ x_{i,1} & \cdot & \cdot & \dots & \cdot \\ & \cdot & \cdot & \dots & \cdot \\ x_{m,1} & \cdot & \cdot & \dots & x_{m,n} \end{matrix} \quad (2)$$

V této matici odpovídá element $x_{m,n}$ hodnotě m -tého pixelu na n -té přímce. Metoda reprezentuje údaje podobné těm od Lundströma a Ekludha [1].



Obr. 3.1: Schématická reprezentace vady nervových vláken na sítnici. Šedý stupeň informace je vzorkován podél přímek kolmých k RNFL vzoru. [2]



Obr. 3.2: Průměrování dat pomocí čtyř křivek reprezentujících stupeň šedi přes směr šíření nervových vláken. [2]

Pro snížení šumu v obraze bylo použito průměrování. Šum v RNFL obrazech může být způsoben filmovým zrnem fotografie nebo může být elektronického původu z procesu digitalizace. Průměrovací postup byl použit za předpokladu, že šum je náhodný (isotropický), zatím co RNFL proužky jsou rozloženy pravidelně v téměř paralelních přímkách. Průměrování tak bylo počítáno z hodnot vzniklých podél RNFL přes m následujících přímek a vznikl nový vektor, reprezentující průměr ze sledu m těchto přímek

$$\bar{X}^m = (\bar{x}_1^m, \bar{x}_2^m \dots \bar{x}_n^m) \quad (3)$$

kde

$$\bar{x}_j^m = \frac{1}{m} \sum_{i=1}^m x_{i,j} \quad (4)$$

Průměrování bylo předpokladem pro redukci šumu pouze pro omezený počet přímek, protože zakřivení proužků RNFL sníží polohu mezi RNFL a směrem průměrování. Nalezení optimálního počtu přímek pak mělo být průměrováno pro zlepšení poměru signál/šum bez nežádoucího zkreslení signálu. V této studii se vždy počítaly rozdíly mezi následnými průměry z 20 přímek obrázku. Tyto následné rozdíly byly definovány jako

$$diff(m) = \sum_{j=1}^n (\bar{x}_j^{m+1} - \bar{x}_j^m) \quad (5)$$

Pokud je průměrující operátor ideální, rozdíl by měl klesat asymptoticky k nule se zvyšujícím se m . Nicméně se však v experimentech zjistilo, že $diff(m)$ klesá do $m = 4$ nebo 5. Dále už více přímek nepřináší žádný užitek.

V této studii [2] se tedy předpokládalo, že zdravé RNFL proužkování bude mít ve výsledku proměnlivější hodnoty proužkové hustoty přes nervová vlákna, což by mělo dát významně větší hodnoty než podél RNFL. Tato hypotéza byla testována pro každou sadu měření a výsledek zaznamenán jako q hodnota. (q hodnota je zde použita pro naznačení stupně rozdílu mezi dvěma naměřenými hodnotami). A tak pro zdravé oko RNFL se očekávaly hodně nízké q hodnoty a pro jasně viditelné zakrnění RNFL naopak hodně vysoké q hodnoty. Jestliže proměnlivost přes RNFL byla menší než podél, definovala se q hodnota náhodně na $q=1,0$. q hodnoty, které byly vzaty pro každé z pěti měření v každé pozici, byly průměrovány k obdržení q hodnoty pro srovnání.

Měřily se průměrné q hodnoty od pěti pacientů, pěti zdravých (kontrolních) a pěti podezřelých očí. Měřilo se uvnitř oblastí bez žilkové sítě. Průměrná q hodnota $q=0,0009$ pro zdravé oko naznačuje vysokou pravděpodobnost RNFL proužkování, zatímco $q=0,47$ pro nemocné oko naznačuje, že zde není žádný rozdíl mezi proměnlivostí hodnot vzaté přes a podél RNFL proužkování.

S normalizací a korekcí změn hustoty u cév bylo měření shodné s lidským pozorováním skoro všemi experimentálními zkouškami. Ačkoli výsledky měření mimo oblasti cév měly vyšší q hodnoty pro nemocné oči než pro zdravé, tak výsledky přesto nebyly přesvědčivé. Průměrná hodnota pro zdravé oči nemůže být interpretována jako příznačná pro patrné RNFL proužkování. Ve většině případů toto měření souhlasí s lidským pozorováním, které nemůže proužky v měřené oblasti rozlišit.

Sled pozorování měl problém ignorovat celkový vzhled fundu a vyčíslit jen lokální proužkování. Třídění proužkování bylo nevyhnutelně ovlivněné ostatními oblastmi. Korelace mezi tříděními stanovené pozorováním a vypočítaná q hodnota každé polohy byly nicméně významné.

Vyhodnocení RNFL se tedy zdá být důležitou pomocí k diagnóze a sledování nemoci optického nervu. Rozšířená atrofie je nejvíce obvyklá pro ztrátu nervových vláken u glaukomu. Bohužel, rozšířená RNFL atrofie je těžce detekovatelná a je dokonce i velice obtížné stanovit rozšíření změny atrofie za nějaký čas.


Tato práce [2] předpokládala, že RNFL vzor je aproximovaný na lineární proužky. Tento předpoklad nám dovoluje provést prostou redukci šumu (směrové průměrování) a navrhnout variabilní měření. I když RNFL proužkování není zas až tak lineární, lze aproximovat přímkami na krátkou vzdálenost, které se k průměrování použijí. Malé odchylky od linearity jsou součástí neodmyslitelného šumu v obrázku. Lokální normalizace se používá ke kompenzaci změny osvětlení a optické polohy během fotografování fundu. Průměrkováním se filtruje vysokofrekvenční izotropní šum způsobený filmovou zrnitostí a elektronický šum v digitálním systému.

3.3 Kvantitativní hodnocení ztráty vrstvy nervových vláken v digitálních barevných oftalmologických obrazech

Studie „Statická analýza vrstvy nervových vláken v barevných digitálních fotografiích sítnice“ [5] je jednou z prvních studií, která se zabývá metodikou kvantitativního hodnocení fokálních výpadků RNFL v digitálních barevných oftalmologických obrazech. U většiny předešlých prací, které se touto problematikou zabývaly, se jednalo především o popis matematických postupů pro detekci RNFL. Jejich výsledky však zůstávají na úrovni základního výzkumu a tudíž bez praktické aplikace.


Pro tuto studii byly použity barevné snímky sítnice pomocí fundus kamery Canon CF60Di s digitální zrcadlovkou Canon EOS 20D. Velikost snímků byla 3504 x 2336 pixelů a velikost snímaného zorného pole byla 60 stupňů. Snímky byly snímány ve formátu JPG s velmi malým kompresním poměrem, což je pro počítačovou analýzu nezbytné. Snímání bylo prováděno za použití bílého zdroje světla (tzv. RGB snímek).

Do této studie byly zařazeny jak snímky očí pacientů se zřetelnými výpadky RNFL, tak i zdravých očí (použité jako kontrolní). V každém z těchto snímků byly manuálně označeny oblasti, které obsahovaly výpadek RNFL (skupina A) a oblasti, které neobsahovaly výpadek ale byly pořízené ze snímku pacienta s atrofií RNFL (skupina B). Kontrolní skupinu tvořily oči, u kterých nebyl výpadek RNFL pozorován v žádné části snímku (skupina C). Velikost oblasti byla zvolena 41 x 41 pixelů, což vyplývalo z velikosti tkáňových struktur v obraze. Jistě by byla vhodnější pro hodnocení oblastí i větší velikost, avšak je nutné vzít v úvahu především cévní řečiště, které je poměrně husté a do vybraných oblastí nesmí zasahovat, aby neovlivnilo následné výpočty.



Obr. 3.3: Ukázka výběru vzorků. [5]

Snahou bylo především nalézt takové parametry vybraných oblastí, které popisují vzorky tak, aby na základě nich bylo možné snadno odlišit, zda se jedná o oblast s výpadkem RNFL, či nikoli. Již prvním pohledem na vybrané vzorky (Obr. 3.4 a,b,c) lze usuzovat, že takové parametry budou zcela jistě existovat.



Obr. 3.4: Ukázka vybraných vzorků: (a) pro oblasti s výpadkem RNFL u skupiny A, (b) mimo oblast s výpadkem pro nemocné oko u skupiny B, (c) vybrané vzorky zdravých očí s neporušenou RNFL u skupiny C. [5]

Technika získávání parametrů je taková, že v každé skupině jsou pro jednotlivé vzorky tkání určeny a statisticky vyhodnoceny parametry lokálních statistik. Jedná se o tyto parametry:

- průměr odstínu stupňů šedi - μ
- směrodatná odchylka odstínu šedi - σ
- variační koeficient vc jako poměr $vc = \sigma/\mu$
- koeficient šikmosti histogramu - γ_1
- koeficient špičatosti histogramu - γ_2

Koeficient šikmost γ_1 je mírou souměrnosti histogramu a koeficient špičatosti γ_2 je mírou strmosti histogramu. Histogram je graf, který ukazuje četnost jednotlivých odstínů stupňů šedi, kde na vodorovné ose jsou jednotlivé odstíny šedi (0-černá, 255-bílá) a na svislé ose je pak počet pixelů, které mají danou úroveň šedi.


Ke kvantitativnímu pozorování lze použít t-test, který slouží k testování rozdílu mezi populačním průměrem daného parametru (ze skupiny A nebo B) a populačním průměrem stejného parametru v kontrolní skupině (ze skupiny C). Sledují se zde rozdíly mezi dvěma výběrovými průměry [6].

Z výsledků t-testu pro sledované parametry pak lze usoudit, že existuje statistický rozdíl mezi průměrnými hodnotami parametrů μ , σ , vc a γ_2 . Parametr γ_2 však trpí poměrně velkým rozptylem, zvláště ve skupině A. Je proto nevhodný.

Histogramy se v této studii používaly pro odhad rozložení pravděpodobnosti hodnot úrovně šedi pro všechny tři skupiny. Získaly se tak tři průběhy, které jsou zobrazeny na Obr. 3.5 a udávají, s jakou pravděpodobností se jednotlivé úrovně stupňů šedi objeví v jednotlivých skupinách A, B a C. Je vidět, že se průběhy pro jednotlivé skupiny poměrně značně liší. Jednou z veličin, na kterou má průběh rozložení histogramu vliv je entropie, která je zde použita jako další sledovaný parametr. Entropie je definována takto:

$$E = -\sum_{i=1}^N p(x_i) \cdot \log(p(x_i)) \quad (6)$$

Parametr $p(x_i)$ je pravděpodobnost s jakou se vyskytuje určitá úroveň šedi v obraze a je získána z takových obrázků, jaké jsou jako příklad uvedeny na Obr. 3.4. N je pak celkový počet úrovní šedi.



Obr. 3.5: Odhady rozdělení pravděpodobnosti z vybraných vzorků v jednotlivých skupinách. [5]

Z hodnoty parametru průměru odstínu stupňů jasu μ lze vidět, že ve skupině C bude tato hodnota poměrně velká. To souvisí i s pozorováním, že oblasti obrazu, kde vrstvy nervových vláken jsou, se projevují jako světlejší. Problémem ale je, že tato úroveň šedi se mezi jednotlivými měřeními liší. Závisí např. na velikosti zornice, spolupráci pacienta, atd. Nelze tedy nalézt vztah mezi hodnotou stupně šedi a tloušťkou RNFL. To lze provést relativně v rámci jednoho snímku. Průměr je proto jako obecný parametr pro kvantifikaci nevhodný.

Jako vhodný parametr se jeví směrodatná odchylka σ , kterou je možné odlišit výpadek RNFL od zdravé tkáně a použít pro případné porovnání snímků (např. pro srovnání snímků s časovým odstupem a sledování zhoršování atrofie RNFL). Ve této studii [5] vyšla nejmenší hodnota směrodatné odchylky σ pro skupinu A, což se dalo předpokládat, protože vrstva nervových vláken se projevuje jako jemná (opakující se) struktura a pokud tato struktura zmizí, zmenší se právě směrodatná odchylka.

Dalším vhodným parametrem pro odlišení výpadku je entropie E . Nejmenší hodnotu entropie mají vzorky ve skupině A, což si lze vysvětlit tím, že při výpadku se ztratí charakteristická struktura a vzorek je více homogenní. V Obr. 3.5 to odpovídá výrazné hodnotě v rozložení pravděpodobnosti, která reprezentuje pixely s úrovní kolem hodnoty 128. To je dáno tím, že struktura RNFL ve skupině A není přítomna, na rozdíl od skupiny C, kde jsou zastoupeny pixely v celém rozsahu od 0 do 255 s přibližně Gaussovým rozložením.

4. Návrh detekce proužkové struktury na umělých vzorcích

4.1 Dvojměrná Fourierova transformace


Jelikož je při návrhu následující metody detekce použita dvojměrná Fourierova transformace, měly by se zde nejdříve popsat její základní vlastnosti.

Dvojměrná Fourierova transformace je bezprostředním zobecněním transformace jednorozměrné.


$$F(u, v) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) e^{-j(ux+vy)} dx dy \quad (7)$$

Jde o převod z originální oblasti (x, y) do spektrální roviny, tzv. (úhlových) prostorových kmitočtů (u, v) . Prostorový kmitočet udává počet cyklů jednotlivé harmonické komponenty obrazu na jednotku délky. Transformace $F(u, v)$ vyjadřuje, obdobně jako u jednorozměrných spekter, jaké parametry mají jednotlivé harmonické komponenty, z nichž se obraz skládá[4].

Tyto komponenty představují v obraze plynule, harmonicky proměnné, proužkové struktury, jejichž hustota proužků odpovídá prostorové frekvenci. Vzdálenost hřebene této funkce, tj. nejbližší nejjasnější přímky ve struktuře od počátku originální roviny (x, y) , je dána fází složky, a směr kmitočtů u/v určuje směr „šíření“, tedy orientaci proužků ve vztahu k osám souřadnic. Vzhledem k tomu, že básovými funkcemi transformace jsou komplexní exponenciály, jsou spektrální reprezentací takové harmonické komponenty dvojice impulsů, umístěných ve 2D případě v bodech spektrální roviny, symetrických vůči počátku. Vzdálenost těchto bodů od počátku frekvenčních souřadnic odpovídá frekvenci složky. Velikost váhy obecně komplexních impulsů pak značí její amplitudu. Fázový úhel spojnice bodů vůči ose u ve frekvenční rovině odpovídá úhlu „šíření“ složky, tj. směru kolmice k hřebenům složky vůči ose x v originální rovině. Je zřejmé, že otočení obrazu kolem počátku v originální rovině je roven otočení jeho spektra o stejný úhel kolem počátku ve spektrální rovině. Více v publikaci [4].



(a)




(b)

Obr. 4.1: (a) zobrazení proužkové struktury v originální oblasti, (b) zobrazení proužkové struktury ve spektrální oblasti po dvojměrné Fourierově transformaci. Jsou zde nepatrně vidět dvě tečky, jejichž spojením dostaneme směr kolmý ke směru proužků v originální oblasti. Obrázek je invertovaný, kvůli lepšímu zviditelnění teček

4.2 Detekce proužkové struktury pomocí frekvenčního spektra

Při této metodě detekce se vychází z toho, že nervová vlákna mají jistou proužkovou strukturu. Tedy nějaké periodické opakování, které by se dalo, pomocí výše zmíněné dvojrozměrné Fourierovci transformace, lehce rozpoznat. To je dáno tím, že Fourierova transformace zobrazí všechny frekvence, které jsou v obrázku obsaženy. Je známo, že při odumření nervových vláken ztrácí poškozená oblast právě toto proužkování a jeví se na pohled jako homogenní. Fourierova transformace zde pak nemůže najít žádné charakteristické frekvence pro nervová vlákna.

Jelikož je velice složité tuto metodu použít přímo na reálných digitálních barevných oftalmologických obrazech (z důvodů omezeného rozlišení a všudypřítomného cévního řečiště, které by Fourierovu transformaci značně ovlivnilo), je pro studování a ověření této metody použito uměle nadefinované matice. Ta simuluje zmíněnou proužkovou strukturu (Obr. 4.1). Pro začátek se předpokládá nezašuměná matice proužků. Černé proužky mají hodnoty všech pixelů rovny nule, bílé pak jedničky.



Obr. 4.2: Matice proužků, která simuluje uspořádání nervových vláken.

Z popisu dvojdimenzionální Fourierovi transformace plyne, že pokud je originálním obrázkem nějaká proužková struktura, tak nejen, že se dá detekovat frekvence, s jakou se proužky střídají, ale i směr jejich šíření. Toho se při této metodě využívá. Detekuje se tedy jak samotná proužková struktura, tak i její natočení.

Jako výchozí směr proužků se bere svislý směr viz. Obr. 4.2. Tyto proužky se pak pomocí funkce *imrotate*, která je v programu Matlab již předdefinována, natáčely o libovolný úhel (v tomto případě 30°). Následně se zkoušelo tento úhel natočení zpětně detekovat. Jelikož se vlivem natočení celé matice proužků vytvořily v rozích nové matice nulové hodnoty (viz. Obr. 4.3a), které by výpočet spektra ovlivnily, musela se tedy z tohoto obrázku vybrat pouze užitečná část. Tedy ta část, ve které se tyto nulové hodnoty nevyskytují (viz. Obr. 4.3b).




(a)



(b)

Obr. 4.3: (a) Natočení matice proužků o úhel 30° , (b) oříznutí na užitečnou oblast proužků


Upravený obrázek se již pomocí Fourierovi transformace převede do spektrální roviny tzv. (úhlových) prostorových kmitočtů. Výsledné spektrum tohoto obrázku je ukázáno na Obr. 4.4.



Obr. 4.4: Výsledná spektrální rovina prostorových kmitočtů

Ve spektru jsou patrné tři výrazné oblasti. Prostřední znázorňuje pouze jakousi střední hodnotu obrázku (velmi nízké frekvence), která ale není pro další zpracování důležitá. Podstatné jsou dvě krajní oblasti, které už značí, že v originálním obrázku byla nějaká proužková struktura o určité frekvenci a natočení. Jak už je popsáno výše, tak natočení proužků v originální oblasti je kolmé na myšlenou přímku, která spojuje tyto dvě oblasti. Oblasti jsou vždy symetrické podle středu.

K automatické detekci směru šíření proužků proto stačí pouze jedna z těchto oblastí. Pomocí goniometrických funkcí a Pythagorovy věty je pak možno hledaný úhel vypočítat. Spektrum se tedy upraví tak, aby zůstala pouze jediná výraznější oblast (použila se k tomu maskovací matice viz. Obr. 4.5). Poté se určí souřadnice pixelu s maximální hodnotou, která byla přibližně uprostřed této oblasti. Po získání této souřadnice se již, pomocí Pythagorovy věty a následně goniometrických funkcí, dá vypočítat úhel natočení proužků. Je nutno podotknout, že obrázek se natáčel proti směru hodinových ručiček, což pak odpovídá i úhlu. V tomto případě tedy vyšel úhel 30° , což byla přesně hodnota, o který se původní matice proužků natočila. Pro přesnější výpočet se ještě před nalezením souřadnice pixelu s maximální hodnotou, pomocí funkce *imresize* (je opět součástí programu Matlab), zvětší velikost matice spektra na 512×512 pixelů.



Obr. 4.5: Upravené spektrum, které se použilo k vlastnímu výpočtu úhlu natočení proužků.

V ideálním případě, kdy není přítomný žádný šum a v matici jsou obsaženy jen proužky jedniček a nul, metoda funguje spolehlivě. Teď se přidá k počáteční podmínce zašumění. Toho se dosáhne prostým přičtením Gaussovského šumu (ideální „bílý“ šum) k matici proužků (Obr. 4.6). Celý postup výpočtu úhlu natočení je pak zcela totožný s již výše popsaným postupem.

Je zřejmé, že správnost výpočtu bude záležet na velikosti použitého šumu. Ten se pro jednotlivé zkoumání nastavuje pomocí hodnoty SNR . Ta udává poměr signál/šum pomocí tohoto vztahu:

$$SNR = 10 \log \frac{W_{obr}}{W_{sum}}, \quad (8)$$

kde

$$W_{obr} = \frac{1}{N} \sum_{i=1, j=1}^{m, n} x_{i,j}^2 \quad (9)$$

a

$$W_{sum} = \frac{1}{N} \sum_{i=1, j=1}^{m, n} y_{i,j}^2 \quad (10)$$

Parametr W_{obr} udává součet kvadrátu hodnot všech pixelů v originálním (nezašuměném) obrázku vydělený počtem pixelů. Tomuto parametru se taky říká směrodatná odchylka. Parametr W_{sum} pak udává směrodatnou odchylku pro generovaný šum, který k originálnímu obrázku přičítáme. Směrodatná odchylka je parametr, který udává kvadratický průměr odchylek hodnot znaku od jejich aritmetického průměru.



(a)



(b)

Obr. 4.6: Zašuměné matice proužků, (a) poměr signál/šum $SNR=8,9$, (b) poměr signál/šum $SNR=5,7$


Metoda detekce úhlu natočení zašuměných proužků se prováděla pro hodnoty poměru signál/šum SNR v rozmezí od 5,3 do 8,9. Větší hodnota znamená, že v matici, která se bude podrobovat Fourierově transformaci, je větší podíl signálu ku šumu. Na obrázku Obr. 4.6 vidíme, že u hodnoty $SNR=5,7$ je proužková struktura již značně porušená. Výsledná spektra z těchto zašuměných obrázků jsou znázorněna na Obr. 4.7.

Pokud byl poměr signál/šum $SNR=8,9$, tak nalezení úhlu natočení proužků se povedlo bez sebemenší odchylky. Na obrázku Obr. 4.7 je vidět, že oblast vyšších hodnot je již o něco větší, než v případě proužků bez šumu. Nemá už ani tak kruhový tvar s maximální hodnotou uprostřed. I přesto byla tato metoda úspěšná. To hlavně díky tomu, že metoda byla ještě schopna správně určit souřadnice pixelu s nejvyšší hodnotou, která je stále přibližně ve stejných místech jako při pokusu s nezašumělým obrázkem. Už se ale začínají objevovat menší oblasti (především ve svislém směru), kde se tvoří „falešné“ vysoké hodnoty.


Při pokusu s poměrem signál/šum $SNR=5,7$ už jde jasně vidět, že pixel s nejvyšší hodnotou se přesunul mnohem blíže ke středu. V tomto případě se již nedá efektivně použít Pythagorova věta a goniometrické funkce pro získání přesného úhlu natočení proužků. Po každém opakování výpočtu vyšel jiný úhel natočení.

Pokud by se poměr signál/šum ještě snížil pomocí přidání většího šumu, tak tento výpočet můžou ještě ovlivnit již výše zmíněné „falešné“ oblasti s vysokými hodnotami. Ty se začnou objevovat především na svislé a vodorovné střední ose. Při hodně nízkém poměru signál/šum (menší jak $SNR=5,5$) pak mohou obsahovat pixel s nejvyšší hodnotou, který by měl pro náš výpočet zcela nevhodné souřadnice.

Zjistilo se, že automatickou detekci úhlu natočení proužků je schopna tato metoda správně provést od poměru signál/šum $SNR=8,5$ a výš s přesností na 1° . Pokud je poměr signál/šum menší než tato hodnota, tak výsledky se už s opakováním měření liší. Přesto je ale, až do nízkých hodnot SNR , stále vidět jen pouhým okem, směr (pozice) jasnějších oblastí. Proto se dá předpokládat, že při přesnějším určení pozice těchto oblastí, bude možné detekovat úhel natočení proužků i pro mnohem nižší poměr signál/šum.



(a)



(b)

Obr. 4.7: (a) spektrogram pro $SNR=8,9$, (b) spectrogram pro $SNR=5,7$.

4.3 Detekce proužkové struktury pomocí spektrogramu


U této metody se jako matice, kterou chceme detekovat, použil také obrázek Obr. 4.2, resp. nějaké její natočení. Postup detekce byl ale v tomto případě odlišný. Nepoužívala se zde dvojrozměrná Fourierova transformace, jako v předchozím případě, ale pouze jednorozměrná Fourierova transformace. Tou se hledaly frekvenční změny na svislé přímce uprostřed zkoumané matice, jak je naznačeno červenou přímkou na Obr. 4.8.



Obr. 4.8: Naznačení přímky, pro kterou byla počítána Fourierova transformace pro různé úhly natočení proužků ($0 - 180^\circ$)

Vychází se z toho, že postupným natáčením matice proužků se mění i její kmitočtové spektrum. Je zřejmé, že pokud jsou proužky přesně svislé, tak v tomto okamžiku bude mít kmitočtové spektrum nulovou (pro matici bez šumu), popř. nejmenší hodnotu (pro matici s obsaženým šumem). Toho se pak při detekci natočení proužků využívá.

Aby se tedy dal detekovat nějaký úhel natočení proužků, musí se nejprve, stejně jako u předešlé metody, libovolně vygenerovat počáteční natočení, které se bude zpětně zjišťovat (v tomto případě bylo počáteční natočení 20° viz. Obr. 4.8(b)). Pomocí funkce *imrotate* se pak nechají proužky otáčet kolem své osy až po úhel 180° . Pro každý úhel z tohoto intervalu se počítá vlastní spektrum. Matice proužků se nechává otáčet o úhel 180° , aby byla jistota, že se narazí na směr, ve kterém nebude žádné periodické opakování. Tím směrem je v tomto případě svislý směr proužků. Tato jednotlivá spektra se pak naskládají vedle sebe do jedné matice (spektrogramu), kde osa x znázorňuje úhel natočení a osa y pak samotné kmitočtové spektra viz. Obr. 4.9.




Obr. 4.9: Spektrogram, který se získal z otáčení matice proužků o počátečním natočení 20° .

Ve spektrogramu je jasně viditelná tmavá oblast nulových hodnot, nazýváme ji oblast- β , která reprezentuje spektra, kde Fourierova transformace nenašla žádné periodické opakování. Z obrázku Obr. 4.9 vyplývá, že aby se našli spektra, kde není obsažena žádná frekvenční složka, musela se matice proužků (Obr. 4.8(b)) otočit o úhel kolem 160° . Šířka oblasti- β záleží na samotné šířce proužků. Pokud jsou proužky širší, tak i při mírném naklonění, nemusí dojít k tomu, že se na svislé přímce, kde počítáme pomocí Fourierovci transformace kmitočtové spektrum, se objeví nějaké opakování, nebo alespoň přechod. Při tenkých prouzcích stačí už sebemenší natočení k tomu, aby se nějaká periodičnost zachytila.


Jelikož ale byla pro Fourierovu transformaci vybrána přímka, která leží přesně uprostřed černého proužku (viz. Obr. 4.8(a)), tak se dá předpokládat, že hledaný úhel, o který se musí původní natočenou matici otočit, aby proužky byly přesně svislé, leží přesně uprostřed oblasti- β . Hledaný úhel, který svírají svislé proužky originální matice s proužky uměle natočenými, je pak roven hodnotě $180 - \text{úhel pro střed oblasti-}\beta$. V tomto případě se tedy původní úhel natočení proužku rovná: $180 - 160 = 20^\circ$.

K automatické detekci úhlu natočení proužků se použilo následujícího postupu. Nejprve se sečtou všechny hodnoty spektrogramu v jednotlivých sloupcích (pro jednotlivé úhly). Z toho vznikne vektor, jehož hodnoty jednotlivých pixelů reprezentují průměrné rozložení velikosti hodnot pro určité úhly. Ty se pak pro lepší zpracování upraví do intervalu od 0 do 1 (viz. Obr.4.10(a)). Aby se lépe zvýraznila oblast- β , použilo se prostého prahování, s rozhodovací úrovní 0,2, kde všechny hodnoty větší než tato hodnota byly rovny jedničce a všechny menší rovny nule (viz. Obr. 4.10(b)). Prahovací hodnota byla v tomto případě stanovena zcela náhodně. Lze předpokládat, že při nějakém větším šumu by se tento způsob zvýraznění použít nedal a musela by se hledat jiná alternativa. V tomto případě je ale tento způsob dostačující.




Obr. 4.10: (a) Graf, který ukazuje, jaká „energie“ je obsažena v jednotlivých úhlech natočení proužků, (b) upravený graf po prahování.

Po této úpravě se pomocí funkce *diff*, která počítá rozdíly mezi sousedními pixely, detekovaly okraje oblasti- β (viz Obr. 4.11). Tato funkce je také součástí programu Matlab. Teď už stačí jenom najít souřadnice, kde se objevil rozdíl mezi sousedními pixely a vzít jejich aritmetický průměr. Tím se detekuje přesně střed oblasti- β . Tato souřadnice (úhel natočení, po kterém mají proužky svislý směr) se pak odečte od hodnoty 180 a získá se tak přesně úhel, který svírají proužky v originálním obrázku vůči svislému směru.




Obr. 4.11 Graf, zobrazující absolutní difference mezi sousedními pixely.

Jako u předchozí navržené metody, se i tato metoda zkoušela použít na zašuměné obrázky. Míra šumu se opět hodnotí podle již výše definovaného poměru signál/šum (SNR). Jak se dá vidět na obrázku Obr. 4.13, tak již docela malé zašumění ($SNR=11,2$) způsobuje to, že pouhým okem lze jen s těžší pozorovat oblast- β , jejíž detekce je pro tuto metodu tak podstatná. Tady se již bez výše zmíněné automatické detekce nelze obejít.




Obr. 4.12: Matice proužků poškozená šumem (poměr signál/šum $SNR=11,2$)



Obr. 4.13: Spektrogram získaný ze zašuměné matice natočených proužků o $SNR=11,2$.

Jak potom vypadá vektor součtu hodnot všech pixelů pro každý sloupec, je ukázáno na obrázku Obr. 4.14. Upravené grafy po prahování a graf zobrazující difference mezi jednotlivými pixely vypadají stejně, jako v případě vstupního obrázku proužků bez šumu.



Obr. 4.14: Graf, který ukazuje, jaká „energie“ je obsažena v jednotlivých úhlech natočení zašuměných proužků ($SNR=11,2$).

Konečný výsledek detekce úhlu pro zašuměnou vstupní matici natočených proužků, vyšel stejně jako v případě vstupní matice bez šumu, a to 20° . I přes to, že ve spektrogramu byla oblast- β pomocí pouhého pohledu jen stěží detekovatelná, povedlo se, pomocí navržené metody, určit úhel natočení.

Při experimentech, s přidáním vyšší hodnoty šumu, již ale tato metoda nebyla tak spolehlivá. Mezní hodnotou poměru signál/šum, při které byla metoda po mnoha opakování vždy úspěšná, je právě hodnota použitá u výše uvedeného příkladu. Tou hodnotou je $SNR=11,2$. Při menší hodnotě sice mohla metoda také vypočítat správný úhel natočení proužků, ale s opakováním výpočtu se stávalo, že úhel byl vypočítán i chybně. To je způsobeno především chybou v detekci oblasti- β . Šum už je totiž tak veliký, že se může stát, že pro určitý úhel natočení má spektrum nižší energii (součet hodnot všech pixelů pro jeden sloupec spektrogramu), než v oblasti- β . To má potom za následek, že se právě tato oblast- β může, pomocí navrženého prahování, špatně detekovat.

Možností, jak by se dalo tomuto nepříznivému vlivu částečně zamezit, je pokusit se „vyhladit“ vektor součtů hodnot všech pixelů v jednotlivých sloupcích tak, aby zde nebyly žádné nahodilé odchylky, které by měly menší hodnotu energie než zvolený práh. To by se dalo realizovat např. prostým mediánovým filtrem. Ten z určitého okolí jednotlivého pixelu vezme hodnotu pixelu, který má právě střední velikost, a dosadí ji místo hodnoty pixelu, pro nějž se hodnota počítá. Tady by se ale muselo dát velký pozor na to, z jak velkého okolí se tato hodnota bude počítat.


5. Návrh detekce nervových vláken na reálných obrázcích

5.1 Úprava barevných oftalmologických obrazů a vhodný výběr vzorků

V předchozí kapitole je popsáno, že k detekci nervových vláken se dá využít její typická proužková struktura. Ta by se prováděla pomocí zkoumání frekvenčních spekter jednotlivých vzorků. V této kapitole bude ukázáno, jak to vypadá s detekcí proužkové struktury na již reálných obrázcích. Je jisté, že podíl šumu zde bude mnohem větší a i proužková struktura v reálných vzorcích nebude dokonale přímočará, jako ve vzorcích, které byly uměle navrhnuty.

Velice důležitý je výběr vzorků, který se bude podrobovat zkoumání. Vzorky, u kterých se zjišťuje přítomnost či nepřítomnost nervových vláken (proužkové struktury), nesmí být příliš velké, aby do těchto vzorků nezasahoval žilní systém a tím neovlivňoval zkoumání. Navíc je zapotřebí, aby směr nervových vláken byl lineární, což se výběrem malých oblastí přibližně dosáhne. Na druhou stranu tyto vzorky nesmí být příliš malé, aby byla proužková struktura vůbec patrná. Výběr vhodných vzorků je tedy pro další zpracování klíčový.

V tomto případě se pracuje s barevnými oftalmologickými obrazy sítnice o velikosti 3504 x 2336 pixelů. Velikosti vzorků, které se použijí pro naše zkoumání, jsou 41 x 41 a 64 x 64 pixelů. Jsou to velikosti, na kterých je již jasně patrná proužková struktura. Navíc jsou dostatečně malé, aby se mohl, z dostupných oftalmologických obrazů, nasbírat vhodný počet testovacích vzorků bez přítomnosti žilního systému.



Obr. 5.1: Příklad barevného oftalmologického obrazu sítnice levého oka.

Barevné oftalmologické obrazy byly snímány ve formátu JPG. Snímky, které se využily k dalšímu zpracování, byly pořízeny za použití zeleného excitačního filtru, který potlačuje spektrum světla odpovídající červené oblasti (tzv. GB snímek). To proto, že na fotografiích, které neobsahují červenou složku, lze lépe vidět strukturu nervových vláken a případných výpadků. Zjistilo se, že tento zelený excitační filtr není nezbytný, protože vynecháním červené složky z digitálního RGB snímku dostaneme téměř stejný obraz jako GB snímek.

Jelikož oftalmologické obrazy sítnice ve formátu JPG jsou složeny ze tří matic (R, G a B), musí se nejprve upravit tak, aby se dalo pracovat pouze s jednou maticí. Na základě předešlého odstavce se to provede tak, že R matice se nebude vůbec uvažovat a G a B matice se na příslušných pixelech sečte a podělí dvěma. Tím se dostane matice, která je tvořena průměrem mezi G a B složkou.

Tímto způsobem vznikne černobílý obraz sítnice tvořený jednou maticí, se kterou se dá jednodušeji pracovat, a na které je jemné proužkování nervových vláken či jejich výpadek i pouhým okem jasně patrný.

Velice důležitá je i celková kvalita snímku. Např. nadměrná „přesvětlenost“ snímku zapříčiní zhoršení rozpoznání mezi oblastí výpadku nervových vláken a oblastí, kde nervová vlákna jsou zachována. V neposlední řadě je důležitou vlastností vhodného obrázku pro zpracování, mít co nejvyšší rozlišení. Díky tomu existuje více vzorků požadované velikosti, do kterých nezasahuje žilní systém.



Obr. 5.2: Příklad upraveného oftalmologického obrazu sítnice levého oka.


5.2 Porovnávání výkonů v různých oblastech spekter

Jak je již uvedeno v kapitole 4, pomocí frekvenčních spekter lze detekovat proužkovou strukturu, což se dá také využít pro detekci nervových vláken na sítnici, které se touto strukturou vyznačují. V této metodě se budou porovnávat výkony v různých oblastech spektra vzorků, obsahujících nervová vlákna (zdravé vzorky) a vzorků, u kterých tato nervová vlákna chybí (nemocné vzorky). Cílem porovnávání těchto výkonů je najít oblasti, ve kterých se spektra zdravých a nemocných vzorků výrazněji liší. Výkony by tak reprezentovaly parametry, pomocí kterých by se mohlo určit, zda se jedná o vzorek, který obsahuje či neobsahuje nervová vlákna (proužkovou strukturu).


Na obrázcích Obr.5.3 a Obr.5.4 jsou příklady zdravých a nemocných vzorků. Byly vybrány ručně tak, aby neobsahovaly žilní systém a tím neznehodnocovaly výsledky. Na první pohled je zde patrná odlišnost mezi těmito vzorky. Zatím co nemocné vzorky vypadají, jakoby obsahovaly pouze šum, u zdravých vzorků je jasně viditelná charakteristická struktura, která má určitou směrovost. Ta připomíná již zmíněné proužkování.

U této metody se porovnávají spektra vzorků o velikosti 41 x 41 pixelů, což je velikost, při které už lze dobře rozeznat struktura vzorku. Navíc je dostatečně malá, takže je možnost získat větší množství vzorků, aniž by byly znehodnoceny žilním systémem. Pro ověření této metody bylo použito 170 zdravých a 170 nemocných vzorků. Tento počet už zaručuje dostatečnou korektnost výsledků metody.


Díky rozdílnosti zdravých a nemocných vzorků se zdá být pravděpodobné, že nějaké oblasti, ve kterých se budou výkony podstatněji lišit, určitě existují. Tuto hypotézu potvrzují i spektra zdravých a nemocných vzorků na obrázcích Obr.5.5 a Obr.5.6, kde lze pouhým okem pozorovat, že u spekter zdravých vzorků je energie soustředěna spíše do středu spektra (k nižším frekvencím). U spekter nemocných vzorků je pak energie více rozptýlena i do vyšších frekvencí. U spekter zdravých vzorků navíc lze pozorovat jistou směrovost, ale o tom je zmínka až v další kapitole.




Obr. 5.3: Příklad zdravých vzorků (41 x 41 pixelů).



Obr. 5.4: Příklad nemocných vzorků (41 x 41 pixelů).



Obr. 5.5: Příklady spekter zdravých vzorků.




Obr. 5.6: Příklady spekter nemocných vzorků.

Tyto příklady spekter zdravých a nemocných vzorků jsou spektra z obrázků Obr. 5.3 a Obr 5.4, které jsou vyobrazeny zcela vlevo.

Stejně jako u spekter uměle vytvořených proužků se odfiltrovala středová část spektra, ve které je obsažena především stejnosměrná složka. Vysoká hodnota stejnosměrné složky by totiž „zastínila“ hodnoty na vyšších frekvencích a všechny spektra by se zdály být velice podobné, tedy s vysokou energií uprostřed. Výpočet výkonů by to nijak neovlivnilo, ale pro posuzování spekter pouhým okem, odfiltrování stejnosměrné složky hodně pomůže.

Základem této metody je rozdělit spektrum na oblasti, ve kterých se počítá jejich výkon. Ten se poté podělí celkovým výkonem spektra, tedy pouze jeho vrchní poloviny (díky symetrii se pracujeme pouze s vrchní polovinou spektra). Získá se parametr, který reprezentuje poměr mezi výkonem dané oblasti a celkovým výkonem spektra. Tím se zjistí, jaká část z celkového výkonu spektra je obsažena právě v dané oblasti.

Jak lze vidět na Obr. 5.7, tak v tomto případě je spektrum rozděleno na 10 oblastí, kde ale vždy osově souměrné oblasti byly při výpočtu výkonu slučovány. To proto, že zahrnovaly stejné frekvence. Tak vzniklo tedy 5 parametrů, které reprezentovaly již zmiňovaný poměr v příslušných oblastech. Tyto parametry se označují PP1 až PP5, kdy parametr PP1 reprezentuje oblast nejnižších frekvencí (modré oblasti) a parametr PP5 oblast nejvyšších frekvencí (červené oblasti). Proč se použila právě tato maska, a jak se vytvořila, je popsáno v podkapitole 5.2.1



Obr. 5.7: Maska, která byla použita pro vymezení oblasti, kde chceme počítat výkon.

Tato maska se tedy použije tak, že oblasti, u které se chce výkon počítat, se přiřadí jednička. Všude jinde bude nula. Takovou maskou se pak vynásobí spektrum, které se bude zkoumat. Tím se ponechají hodnoty, potřebné pro výpočet výkonu v dané oblasti a všechny ostatní hodnoty spektra se vynulují.

Pro výpočet poměru výkonu v dané oblasti ku celkovému výkonu spektra se použije vztah:

$$PP = \frac{W_{obl}}{W_{clk}} \quad , \quad (11)$$

kde

$$W_{obl} = W_{clk} = \sum_{i=1}^m \sum_{j=1}^n x_{i,j}^2 \quad (12)$$


PP zde reprezentuje hledaný parametr, W_{obl} je výkon spektra v dané oblasti zájmu, W_{clk} je celkový výkon spektra, m a n odpovídá počtu řádků a sloupců matice spektra a x reprezentuje hodnotu na příslušném pixelu spektra. Jak plyne ze vztahu 12, výpočet výkonů W_{obl} a W_{clk} je zcela stejný. Jediný rozdíl je v tom, že při výpočtu výkonu W_{obl} jsou veškeré hodnoty pixelů mimo oblast zájmu vynulovány.

5.2.1 Vytvoření vhodné masky


Pro vymezení oblastí, ve který chceme výkon počítat, je důležité vytvořit vhodnou masku, která ponechá hodnoty pouze v této oblasti a všechno ostatní odfiltruje. Spektrum je centrováno do středu. Tzn., že nejnižší frekvence jsou obsaženy ve středu spektra a směrem k okraji frekvence rostou. Stejně frekvence jsou tak vždy na kružnicích se středem totožným se středem matice spektra. Z tohoto důvodu se zdá být nejvhodnější spektrum rozdělit na kružnice o určité šířce a určité vzdálenosti od středu.

Vytvoření takové masky se provede následujícím způsobem:

1. Vygenerují se dvě matice o stejné velikosti jako je velikost matice spektra. Jedna z matic bude mít svislé a druhá vodorovné proužky s hodnotami od -255 do 255. Jelikož se pracuje s maticemi spektra o velikosti 512 x 512 pixelů (sudý počet pixelů ve sloupci i řádku), tak kvůli souměrnosti vůči středu, budou uprostřed dvě nuly za sebou.




(a)



(b)

Obr. 5.8: Matice svislých (a) a vodorovných (b) proužků.


2. Z těchto dvou matic se může pomocí jednoduchých operací získat matice kružnic. Tu vytvoříme pomocí vztahu $K = \sqrt{X^2 + Y^2}$, kde K je výsledná matice kružnic, X a Y pak původní matice proužků. V závorce se sčítají druhé mocniny pixelů obou matic na příslušných souřadnicích. Poté prostým prahováním určíme oblast, kterou chceme ponechat a kterou odfiltrovat.



Obr. 5.9: Matice kružnic.

3. Jak lze vidět na obrázcích spekter v kapitole 4, můžou se na svislé a vodorovné ose objevit falešné frekvence, které v obrázku neexistují. Proto tyto části spektra se nebudou pro výpočet výkonů uvažovat. Bude se tedy pracovat jen s určitou výsečí spektra. Jelikož jsou směry nervových vláken většinou různé od svislého či vodorovného směru, nepředpokládá se v těchto oblastech větší energie. Proto nemusí tyto úzké výseče ve svislém a vodorovném směru brát do úvahy. Metoda se tak vyhne chybám, které by mohly nastat. Je tedy důležité použít i masku, která tyto oblasti odfiltruje. Takováto maska (matice diagonál) se vytvoří pomocí vztahu $D = \text{atan}(X/Y)$, kde D je výsledná matice diagonál, X a Y jsou opět původní matice proužků. V závorce se dělí hodnoty pixelů obou matic na příslušných souřadnicích.

4. Pro lepší práci se převede celá matice diagonál do absolutních hodnot. Poté už se prostým prahováním vymezí oblasti, které se dají odfiltrout (přidělí se hodnota 0).




Obr. 5.10: (a) Matice diagonál, (b) upravená matice diagonál s vyfiltrovanými oblastmi.

Maticí kružnic a upravenou maticí diagonál se dá tedy vytvořit maska, pomocí které se vyberou oblasti, které se budou zrovna zkoumat.

Díky tomu, že spektrum je symetrické vůči středu, stačí zkoumat spektrum jen v jedné půlce (v tomto případě horní). Proto se použije ještě jedna maska o velikosti matice spektra. Tu bude tvořit matice, kde všechny řádky od 0 do 256 budou rovny 1 a řádky od 257 do 512 rovny 0.

5.2.2 Porovnání parametrů v různých oblastech spektra

Na Obr. 5.11 jsou znázorněny grafy, na kterých je vidět, v jaké oblasti spektra je jaký rozdíl mezi parametrem u zdravých a nemocných vzorků. Modrý graf je pro zdravé vzorky, červený graf pro nemocné vzorky. Na ose x je znázorněn počet vzorků, na ose y pak hledaný poměr.




Obr. 5.11: Grafy poměru výkonu v určité oblasti a celkovým výkonem. (a) parametr PP1, (b) parametr PP2, (c) parametr PP3, (d) parametr PP4, (e) parametr PP5, (f) parametr PP45.

Z grafů na obrázku Obr. 5.8 je jasné vidět, že zcela jistě existují ve spektru oblasti, kde se hledaný poměr mezi výkonem dané oblasti a celkovým výkonem liší pro zdravé a nemocné vzorky. Parametry PP2 a PP3 zřejmě žádnou vypovídající hodnotu nemají, jelikož grafy zdravých a nemocných vzorků se dost překrývají. U zbylých 3 parametrů už ale jsou zřetelně viditelné rozdíly mezi zdravými a nemocnými vzorky. V oblasti PP1 je poměr mezi výkonem oblasti a celkovým výkonem u zdravých vzorků jasně vyšší, než u vzorků nemocných. Ještě větší rozdíl mezi parametry zdravých a nemocných vzorků je u oblastí PP4 a PP5. Zde je tomu naopak. Vyšší poměr mezi výkonem oblasti a celkovým výkonem je tentokrát u nemocných vzorků. U zdravých vzorků je tento poměr mnohem menší.

Z důvodu podobnosti grafů poměru výkonu v určité oblasti a celkovým výkonem u parametrů PP4 a PP5, se přidal ještě další parametr. Tím je parametr PP45, který vznikl sloučením oblastí PP4 a PP5 v jednu oblast, která se opět samostatně vyhodnocovala. Tento parametr je spíše informativní, aby se zjistilo, jestli sloučením těchto oblastí nedojde k ještě většímu zvýraznění rozdílu mezi zdravými a nemocnými vzorky. Jak je možné pouhým okem porovnat, tak k žádnému velkému zvýraznění nedošlo. Graf pro parametr PP45 je velice podobný grafům parametrů PP4 a PP5. Proto se tento parametr dále nebude uvažovat.

Tímto způsobem se tedy získaly tři parametry, pomocí kterých se dá s velkou pravděpodobností říct, jestli se jedná o zdravý či nemocný vzorek. Samozřejmě velice záleží na kvalitě vzorku, jak je již zmíněno na začátku této kapitoly. Ne na všech zdravých vzorcích je proužková struktura jasně patrná. To může být zapříčiněno např. vysokou jasovou modulací v oblasti, ze které se vzorek pořizuje. Naopak i některé nemocné vzorky, které by měly obsahovat pouze jakýsi šum, mohou mít ještě slabou proužkovou strukturu, takže se mohou jevit jako zdravé. Proto se grafy všech parametrů u zdravých a nemocných vzorků určitým způsobem překrývají. Někde více (PP2 a PP3), někde málo (PP1) a někde skoro vůbec (PP4 a PP5). Vždycky se ale najde nějaký vzorek, který se podle této metody vyhodnotí jako vzorek opačný, než do jaké skupiny skutečně patří.



Obr. 5.12: Grafy rozložení pro dva různé parametry. Modře jsou znázorněny zdravé vzorky, červeně nemocné vzorky. (a) rozložení pro parametry PP4 a PP5, (b) rozložení pro parametry PP1 a PP5

Zajímavé je sledovat rozložení, kdy se do jednoho grafu vyhodnotí dva rozdílné parametry. Jeden parametr bude reprezentovat osa x, druhý osa y. Na obrázku Obr. 5.12 lze vidět, že by se rozložení parametrů dalo rozdělit na dvě oblasti. Jedna by reprezentovala zdravé vzorky (modrá kolečka) a druhá nemocné vzorky (červená kolečka). Z důvodů, které jsou popsány v předchozím odstavci, se ale tyto oblasti nepatrně překrývají. Proto není nikdy 100% jisté, že zkoumaný vzorek se vyhodnotil pomocí této metody správně. Výsledek se však může brát jako velice pravděpodobný a pro hrubé odlišení zdravých a nemocných vzorků se zdá být tato metoda vhodná.

Také je patrné, že rozložení na obrázcích Obr. 5.12 (a) i (b) má určitou směrovost. Se zvětšujícím se parametrem PP4 se zvětšuje i parametr PP5 a se snižujícím se parametrem PP1 se zvyšuje parametr PP5. Tato skutečnost pokládá otázku, zda tyto parametry na sobě nejsou na tolik vázané, že by stačilo vyhodnocovat pouze jeden z těchto tří parametrů. Musí se tedy zjistit, jestli tyto parametry mezi sebou nejsou v určité korelaci.

K tomuto ověření se použije korelační koeficient, pomocí kterého se dá posoudit, jak moc jsou jednotlivé parametry mezi sebou provázány. Tedy, jak moc jsou mezi sebou korelovány. Více o korelaci a korelačním koeficientu je v podkapitole 5.2.3.

Vypočítané korelační koeficienty mezi různými dvojicemi parametrů pro zdravé i nemocné vzorky jsou přehledně ukázány v tabulkách Tab. 5.1 a Tab. 5.2.

	PP1	PP2	PP3	PP4	PP5	PP45
PP1	1	-0,6875	-0,6653	-0,4686	-0,4977	-0,4919
PP2	-0,6875	1	0,0032	-0,2092	-0,1048	-0,1095
PP3	-0,6653	0,0032	1	0,576	0,5449	0,588
PP4	-0,4686	-0,2092	0,576	1	0,8209	0,9899
PP5	-0,4977	-0,1048	0,5449	0,8209	1	0,8935
PP45	-0,4919	-0,1095	0,588	0,9899	0,8935	1

Tab. 5.1: Korelační koeficienty pro zdravé vzorky

	PP1	PP2	PP3	PP4	PP5	PP45
PP1	1	-0,2553	-0,6214	-0,6238	-0,5658	-0,6628
PP2	-0,2553	1	-0,1991	-0,3664	-0,2224	-0,3567
PP3	-0,6214	-0,1991	1	0,2369	0,2354	0,2578
PP4	-0,6238	-0,3664	0,2369	1	0,5999	0,9714
PP5	-0,5658	-0,2224	0,2354	0,5999	1	0,7726
PP45	-0,6628	-0,3567	0,2578	0,9714	0,7726	1

Tab. 5.2: Korelační koeficienty pro nemocné vzorky

Pro srovnání se dá porovnat obrázek Obr. 5.12 a odpovídající korelační koeficienty s obrázkem Obr. 5.13. Je patrné, že si rozložení s danými korelačními koeficienty přibližně odpovídají.

5. 2. 3 Korelace a korelační koeficient

Korelace značí vzájemný vztah mezi dvěma procesy nebo veličinami. Pokud se jedna z nich mění, mění se korelativně i druhá a naopak. Ukáže-li se mezi dvěma procesy korelace, je pravděpodobné, že na sobě závisejí. Nelze z toho však ještě usoudit, že by jeden z nich musel být příčinou a druhý následkem. To samotná korelace nedovoluje rozhodnout.


Pojem korelace se užívá nejčastěji ve spojení se statistikou, kde znamená vzájemný lineární vztah mezi znaky či veličinami x a y . Míru korelace pak vyjadřuje korelační koeficient, který může nabývat hodnot od -1 do $+1$.

Vztah mezi znaky či veličinami x a y může být kladný, pokud (přibližně) platí $y = kx$, nebo záporný ($y = -kx$). Hodnota korelačního koeficientu -1 značí zcela nepřímou závislost. Čím více se zvětší hodnoty v první skupině znaků, tím více se zmenší hodnoty v druhé skupině znaků. Hodnota korelačního koeficientu $+1$ odpovídá zcela přímé závislosti. Pokud je korelační koeficient roven 0 , pak mezi znaky není žádná statisticky zjištělná lineární závislost. Je důležité si uvědomit, že i při nulovém korelačním koeficientu na sobě veličiny mohou záviset. Pouze tento vztah nelze vyjádřit lineární funkcí, a to ani přibližně.[11]

Vztah pro výpočet korelačního koeficientu:

$$\sigma_{x,y} = \frac{\text{cov}(X,Y)}{\sigma_x \sigma_y} = \frac{E((X - \mu_x)(Y - \mu_y))}{\sigma_x \sigma_y} \quad (13)$$

Vypočítají se aritmetické průměry souborů X a Y ($E(X)$ a $E(Y)$). Vynásobí se sumy čtverců odchylek (μ) od těchto průměrů obou souborů. Tím se spočítá tzv. kovariance, což je však absolutní veličina. Pro výpočet relativní veličiny se tak kovariance dělí odmocninou násobku rozptylu (σ) souboru X a souboru Y . [11]



Obr. 5.13: Příklady grafického zobrazení naměřených dat a koeficienty jejich korelace s funkcí $x = y$. [14]

5. 2. 4 Zhodnocení metody

Metoda detekce nervových vláken pomocí porovnávání výkonů v různých oblastech spekter se zdá být úspěšná. Záleží ale především na tom, v jaké části spektra se výkony počítají a následně porovnávají. Je ukázáno, že v oblastech PP2 a PP3 je energie spektra pro zdravé a nemocné vzorky přibližně stejná. Parametr, kterým se dá určit, zda se jedná o zdravý či nemocný vzorek, se získá buď z nejnižších frekvencí (oblast PP1), nebo naopak z těch nejvyšších (oblast PP4 a PP5). V oblasti PP1 mají zdravé vzorky vyšší energii než ty nemocné. V oblastech PP4 a PP5 zase naopak mají výrazně vyšší energii nemocné vzorky.

Problém této metody spočívá ve stanovení nějakého „energetického“ prahu pro jednotlivé oblasti, který zaručeně rozdělí zdravé vzorky od nemocných. Jelikož proužková struktura nervových vláken není dokonalá, může se stát, že ve zdravém vzorku, který se bude vyhodnocovat, tato struktura nebude dobře patrná. Tudíž bude vyhodnocena špatně. Velice záleží na celkovém rozlišení snímku sítnice. S menším rozlišením klesá schopnost detekce proužkové struktury. Také je důležité vybrat dostatečně velké vzorky, aby zde struktura byla patrná.

V tomto případě byly použity snímky s rozlišením 3504 x 2336 pixelů a velikosti zkoumaných vzorků 41 x 41 pixelů. Toto rozlišení snímků a velikosti zkoumaných vzorků se zdá být adekvátní. Dá se ale předpokládat, že při zkoumání větších vzorků, by byly výsledky metody ještě lepší. Z důvodu hustého žilního systému a podmínce, že proužkování nervových vláken má být lineární, se v tomto případě nedaly použít o moc větší vzorky.

Z tabulky Tab. 5.1 a Tab. 5.2 se dá vyčíst, v jakém korelačním vztahu jsou mezi sebou výkony jednotlivých oblastí. Např. korelační koeficient u zdravých vzorků mezi parametry PP4 a PP5 je 0,82. Dá se říct, že jsou mezi sebou ve vysokém korelačním vztahu. To znamená, že pro posouzení, jestli je vzorek zdravý nám postačí pouze jeden z těchto parametrů. Korelační koeficient u zdravých vzorků mezi parametry PP1 a PP5 pak je roven -0,5. Zde se dá sice vidět taky jistá míra korelace mezi oběma parametry, ale přece jen se zdaleka neblíží absolutní hodnotě 1. Proto se parametr PP1 může uvažovat jako doplňková informace k parametru PP5. Pomocí využití obou parametrů při detekci zdravých či nemocných vzorků, se zvýší její účinnost.


5.3 Určování směru proužkování nervových vláken

5.3.1 Výběr vzorků


Jak je již částečně popsáno v kapitole 4.2, pomocí frekvenčního spektra se dá určit směr proužků, který má zkoumaný vzorek v prostorové oblasti. Ukázalo se, že pro dokonalé periodické proužkování, které je v kapitole 4.2 nasimulováno, lze směr proužků určit bez větších problémů. V této kapitole se popisuje metoda, pomocí které se dá určit směr nervových vláken (proužkování) na reálných vzorcích.

Jelikož u této metody nejde pouze o detekci zdravých či nemocných vzorků, ale pokud jde o zdravé vzorky, tak také o určení směru šíření nervových vláken, je kladen ještě větší důraz na kvalitu vzorků, se kterými se pracuje. V tomto případě se mluví především o dostatečném rozlišení vzorků, nebo-li o dostatečné velikosti vzorků, aby zde mohla lépe vyniknout proužková struktura.

Opět se pracuje s oftalmologickými snímky o velikosti 3504 x 2336 pixelů. Pro metodu určování směru proužkování nervových vláken se již ale nepoužívaly vzorky o velikosti 41 x 41 pixelů, jak tomu bylo u minulé metody. Proužková struktura zde již sice byla jasně patrná, ale směr nervových vláken nebyl vždy zcela jasný. Je potřeba použít vzorky, kde již pouhým okem se dá určit, jakým směrem se nervová vlákna šíří. To z toho důvodu, aby se dalo zpětně porovnat, jestli byla detekce směru pomocí spektra (alespoň přibližně) správná.



(a)




(b)

5.14: Ukázka výběru vzorků. (a) zdravé vzorky, (b) nemocné vzorky


Velikost vzorků, která se zdá být dostatečná pro určení směru šíření nervových vláken, je 64 x 64 pixelů. Ukázka výběru vzorků pro tuto metodu je na obrázku Obr. 5.14. Je opět velmi důležité, aby vzorek neobsahoval ani kousek žilního řečiště. Výskyt žilního řečiště by výrazně ovlivnil výsledek. Mohlo by se např. stát, že místo šíření směru nervových vláken, by tato detekovala směr šíření žilky, kterou vzorek nechtěně obsahuje.

Důsledkem zvětšení vzorků na velikost 64 x 64 pixelů došlo k výraznému zmenšení počtu zkoumaných vzorků. Z dostupných oftalmologických snímků bylo možno získat pouze 30 kvalitních nemocných vzorků, na kterých nebyl obsažen žilní systém. Aby se dosáhlo určité statistické rovnováhy, vybral se i stejný počet zdravých vzorků.

Ukázky zdravých a nemocných vzorků o velikosti 64 x 64 pixelů jsou na obrázcích Obr. 5.15 a Obr. 5.16. Tyto vzorky jsou ale oproti vzorkům z původního obrázku mírně upraveny. To z toho důvodu, že původní vzorky byly jen v malém rozmezí odstínu šedi a tím pádem struktura vzorku zde nebyla na pohled tolik výrazná. Pro úpravu těchto vzorků se použila ekvalizace histogramu, při které se rozmezí odstínu šedi upravilo do maximální dynamiky. Díky této úpravě můžeme bez problému pouhým okem odhadnout směr nervových vláken. Více o úpravě histogramu je v podkapitole 5.3.4.




Obr. 5.15: Příklad zdravých vzorků (64 x 64 pixelů).




Obr. 5.16: Příklad nemocných vzorků (64 x 64 pixelů).

5.3.2 Detekce směru šíření nervových vláken


Už několikrát zde bylo uvedeno a dokázáno, že frekvenční spektra zdravých a nemocných vzorků se v jisté míře liší. To lze vidět i na obrázcích Obr. 5.17, Obr. 5.18 a Obr. 5.19, kde jsou příklady spekter zdravých a nemocných vzorků vyobrazeny. Tato spektra byla upravena pomocí filtrace Hammingovým oknem, aby byl zdůrazněn rozdíl mezi spektry obou skupin. Více o úpravě pomocí filtrace Hammingovým oknem v podkapitole 5.3.5.



Obr. 5.17: Příklad frekvenčního spektra zdravých vzorků.



Obr. 5.18: Příklad výřezů frekvenčních spekter zdravých vzorků.



Obr. 5.19: Příklad výřezů frekvenčních spekter nemocných vzorků.


Na obrázcích Obr. 5.18 a Obr. 5.19 jsou vyobrazeny pouze výřezy celých spekter. To proto, že je u této metody podstatná pouze část spektra blízka středu, která se pro zdravé a nemocné vzorky výrazněji liší. Jak lze vidět, tak spektra nemocných vzorků vypadají, na rozdíl od spekter zdravých vzorků, ve všech případech stejně (podoba „duhy“). Ty se od spekter nemocných vzorků liší tím, že nad pomyslnou duhou je oblast, kde se nachází vyšší energie. Ta u spekter nemocných vzorků vždy chybí.

Pozice, kde se tato oblast v daném spektru nachází, záleží právě na směru vláken, které jsou ve vzorku obsaženy. Jak už je popsáno v kapitole 4 na umělých vzorcích, tak spojnice počátku soustavy souřadnic (středu spektra) s pozicí oblasti o vysoké energii je vždy kolmá na směr šíření proužků. To platí i v případě s reálnými vzorky nervových vláken. Jelikož ale nervová vlákna netvoří ideální proužkovou strukturu, tak proto je oblast vyšší energie tak rozlehlá. Pokud by zkoumaný vzorek měl pravidelnou proužkovou strukturu, tak oblast vyšší energie by byl pouze bod.

Jelikož oblast vyšší energie již není bodová, jak tomu bylo při detekci směru proužků u umělých vzorků, nestačí nám pouze najít pixel o nejvyšší energii, pomocí kterého pak vypočteme úhel, pod kterým se nervová vlákna šíří. Metoda, která je popsána v kapitole 4, se tedy nedá pro reálné vzorky použít. Do výpočtu a určení směru se musí zahrnout větší oblast.


Tato metoda detekce směru šíření nervových vláken vychází z vysoké podobnosti spekter nemocných a zdravých vzorků bez oblasti vyšší energie (tzv. „duha“). Jako oblast zájmu, se kterou se bude pracovat, se vybere půlkružnice o takovém poloměru, aby těsně přiléhala na „duhu“. Šířka se zvolí tak, aby oblast výběru vždy obsahovala oblasti vyšší energie.

Tato oblast zájmu, která se bude dále zpracovávat a vyhodnocovat, se získá opět pomocí masky obdobně, jak je popsáno v podkapitole 5.2.1. Náznak masky, pomocí které se vybere oblast zájmu je na obrázku Obr. 5.20.



Obr. 5.20: Náznak masky, pomocí které vybereme oblast zájmu.

Tato vybraná půlkružnice se dále pravidelně rozdělí na 18 stejných oblastí, kde každá z nich reprezentuje úhel 10° . Jak vypadá vzor masky pro výběr určité oblasti je ukázáno na obrázku Obr. 5.21 .




Obr. 5.21: Vzor masky pro výběr určité oblasti

V každé z těchto oblastí se pak vypočítá výkon podle vzorce (12). Zjišťuje se, kde je tento výkon nejvyšší, čímž se získá směr kolmý ke směru šíření nervových vláken ve vzorku. Jako úhel nejvyšší energie se pak bere střed oblasti, kde byl vypočten nejvyšší výkon (tedy 5° , 15° , 25° ... až 175°).


Směr, pod kterým se nervová vlákna ve vzorku šíří, se díky jeho kolmosti ke spojnici oblasti nejvyšší energie a po počátku soustavy souřadnic určí tak, že k úhlu, ve kterém je nejvyšší výkon, připočteme hodnotu 90° . Jelikož ale směr šíření může být pouze od 0° do 180° , tak od úhlů vyšších než 180° se 180° odečte.

Tím, že jednotlivé oblasti reprezentují vždy úhel v rozmezí 10° , bude odchylka od přesného směru nejvyšší energie maximálně $\pm 5^\circ$. Jelikož se ale pravý směr, se kterým se naměřené úhly porovnají, dá odhadnout jen přibližně, je přesnost odhadu úhlu na $\pm 5^\circ$ dostačující. Příklad ručního odhadu směru nervových vláken je na obrázku Obr. 5.22.




Obr. 5.22: Příklad ručního odhadu směru nervových vláken.

Na obrázku Obr. 5.23 je ukázáno, jak vypadají některá spektra zdravých vzorků v oblasti, kde se zjišťují jednotlivé výkony pro detekci směru šíření nervových vláken. Jestliže se zbytek spektra odfiltruje, tak směr nejvyšší energie se v oblasti zájmu mnohonásobně zvýrazní, což může sloužit pro vizuální kontrolu. Napravo od spekter jsou grafy s výkony v jednotlivých oblastech seřazeny podle narůstajícího úhlu. Tato spektra odpovídají spektrům na obrázku Obr. 5.18. Největší odchylka od skutečného úhlu (tedy $\pm 5^\circ$) nastává, pokud u dvou sousedních oblastí je celkový výkon téměř totožný.



Obr. 5.23: Příklady spekter a jejich výkonů u zdravých vzorků. (a) spektra v oblasti zájmu, (b) výkonů v oblastech daného úhlu.

Na obrázku Obr. 5.24 jsou pro srovnání ukázány spektra v oblastech zájmu nemocných vzorků. Na první pohled je vidět veliký rozdíl mezi spektry zdravých a nemocných vzorků. Zatím co u zdravých vzorků je ve spektru vždy oblast, kde je výraznější energie, tak u spekter nemocných vzorků tato oblast chybí. I na grafech výkonů je vidět výrazná odlišnost. Na rozdíl od zdravých vzorků není u nemocných jasně vidět, v jakém směru je obsažena nějaká vyšší energie. Největší rozdíl je ale hlavně v maximálním výkonu, který je ve směru nejvyšší energie. Tato skutečnost se dá využít pro detekci zdravých a nemocných vzorků. Více v podkapitole 5.3.3.



Obr. 5.24: Příklady spekter a jejich výkonů u zdravých vzorků. (a) spektra v oblasti zájmu, (b) výkony v oblastech daného úhlu.

V tabulce Tab. 5.3 je uveden odhad směru šíření nervových vláken pro všech 30 zdravých vzorků. Dále jsou zde pro každý vzorek 3 vypočtené úhly. První úhel je vypočtený bez jakékoli úpravy vzorku, u druhého se použila ekvalizace histogramu daného vzorku a u třetího je histogram vzorku upraven do jeho plné dynamiky. Více o histogramu a jeho úpravách v podkapitole 5.3.4. U každého vypočteného úhlu je pak uvedena odchylka, o kterou se úhel liší od toho ručně odhadnutého.


Jak jde vidět, tak ve většině případů jsou odchylky od odhadnutých úhlů minimální. Často shodné s odchylkou, která je dána nepřesností metody, tudíž $\pm 5^\circ$. Také velmi záleží na přesnosti ručního odhadnutí směru. Ten není v některých případech zcela jednoznačný. I zde tedy jistě mohly vzniknout nějaké odchylky od přesného směru šíření nervových vláken. Odhady směrů vzorků 6 až 15 jsou ukázány na obrázku Obr. 5.22. Největší odchylka je 30° , ale ta je víceméně ojedinělá. Nejspíše je způsobena nějakým z výše uvedených faktorů. Rozdíly vypočtených úhlů mezi jednotlivými úpravami vzorků jsou ve většině případů minimální. Z toho vyplývá, že jakákoli úprava vzorků pro detekci směru šíření nervových vláken, není nutná.

vzorek	odhadnuté úhly	úhly bez úpravy vzorků		ekvalizace histogramu		plná dynamika histogramu	
	úhel [°]	úhel [°]	chyba [°]	úhel [°]	chyba [°]	úhel [°]	chyba [°]
1	155	165	10	155	0	155	0
2	145	145	0	145	0	145	0
3	135	135	0	135	0	135	0
4	140	155	15	155	15	155	15
5	120	125	5	125	5	125	5
6	110	105	5	105	5	105	5
7	120	105	15	105	15	105	15
8	135	115	20	145	10	115	20
9	45	15	30	15	30	15	30
10	50	45	5	45	5	45	5
11	60	65	5	65	5	65	5
12	60	55	5	55	5	55	5
13	40	35	5	25	15	25	15
14	40	35	5	25	15	35	5
15	45	45	0	25	20	45	0
16	55	55	0	55	0	55	0
17	55	45	10	45	10	45	10
18	60	45	15	45	15	45	15
19	60	55	5	55	5	55	5
20	40	15	5	15	5	15	5
21	65	55	10	65	0	65	0
22	65	65	0	65	0	65	0
23	70	65	5	65	5	65	5
24	70	55	15	55	15	55	15
25	135	125	10	125	10	125	10
26	140	135	5	115	25	125	15
27	135	145	10	125	10	145	10
28	140	135	5	125	15	125	15
29	140	145	5	125	15	145	5
30	60	55	5	60	0	55	5

Tab. 5.2: Tabulka odhadnutých a vypočtených směrů šíření nervových vláken.


5.3.3 Detekce nervových vláken pomocí maximálních výkonů

Cílem této metody sice bylo najít směr šíření nervových vláken, ale může se velice dobře použít i k samotné detekci zdravých a nemocných vzorků. Pokud se porovnají grafy výkonů v jednotlivých oblastech spektra, dá se pozorovat, že maximální výkony u zdravých vzorků jsou mnohonásobně větší než u vzorků nemocných. Tento rozdíl je ukázán na obrázku Obr. 5.25.




Obr. 5.25: Výkony v maximu pro jednotlivé vzorky (modrá = zdravé vzorky, červená = nemocné vzorky).

Na obrázku Obr. 5.26 je pak ukázáno, jak se nám tyto výkony změní, pokud se původní vzorky nějak upraví. Po úpravě vzorků pomocí ekvalizace a využití plné dynamiky histogramu (více v podkapitole 5.3.4) se grafy výkonů zdravých a nemocných vzorků začínají mírně překrývat. Z tohoto pohledu se zdá být nejlepší zpracovávat vzorky bez jakékoli úpravy. Zde by ale bylo velice důležité používat kvalitní oftalmologické snímky, protože např. přesvětlení by mohlo zpracování výrazně ovlivnit.




Obr. 5.26: Výkony v maximu po úpravách vzorku (a) ekvalizace histogramu, (b) plný dynamika histogramu (modrá = zdravé vzorky, červená = nemocné vzorky).

Na obrázcích Obr. 5.27 a Obr. 5.28 jsou ukázány histogramy rozložení zdravých a nemocných vzorků do výkonových úrovní. Tyto histogramy nám ukazují, kolik vzorků má daný výkon. Je zřetelné, že zdravé vzorky mají mezi sebou daleko větší výkonový rozptyl než vzorky nemocné. Na obrázku Obr. 5.27 je dobře vidět, že existuje nějaký energetický práh, kterým by se daly vzorky rozdělit na zdravé a nemocné. Bohužel pro zkoumání této metody bylo k dispozici malé množství vzorků (30 zdravých, 30 nemocných), takže není zcela jisté, kde by tento práh měl přesně ležet. Je velice pravděpodobné, že s větším množstvím zkoumaných vzorků by se výkony některých zdravých a nemocných vzorků mírně překrývaly.



Obr. 5.27: Histogram rozložení zdravých a nemocných vzorků do výkonových úrovní (modrá = zdravé vzorky, červená = nemocné vzorky).

Jak lze vidět na obrázku Obr. 5.28, po úpravě vzorků se již výkony zdravých a nemocných vzorků překrývají poměrně významně. Není je tedy možno použít pro detekci a rozřazení do příslušné skupiny. Z toho plyne, že jakákoli úprava zkoumaných vzorků není pro další zpracování příliš vhodná.




Obr. 5.28: Histogram rozložení zdravých a nemocných vzorků do výkonových úrovní u upravených vzorků. (a) ekvalizace histogramu, (b) plný dynamika histogramu (modrá = zdravé vzorky, červená = nemocné vzorky)

5.3.4 Histogram a jeho úpravy


Histogram je grafická interpretace poměrového zastoupení jasů v obraze. Zobrazuje počet bodů jednotlivých jasových úrovní od bílé až po černou, které jsou v obraze zastoupeny. Maximálně lze rozlišit 256 úrovní jasu (interval $\langle 0;255 \rangle$), kde hodnota 0 značí černou barvu, hodnota 255 bílou. Z histogramu (Obr. 5.30 (a)) je zřejmé, že v obraze většinou schází zejména hodnoty úrovně jasů na okrajích intervalu, což obvykle snižuje kvalitu obrazu. Z grafické podoby histogramu lze tedy usuzovat nejen stav digitálního obrazu, ale také možnosti úpravy obrazu. [9]

Jednou z úprav obrazu je ekvalizace histogramu. Tu lze vidět na obrázku Obr. 5.30 (b). Ekvalizace histogramu je algoritmus, který změní rozložení úrovní jasu v obraze tak, aby se v něm úrovně jasu vyskytovaly v co nejširším rozmezí, a to přibližně se stejnou četností. U obrazů s konečným počtem obrazových bodů se lze tomuto cíli jen přiblížit. Metoda obvykle zvyšuje lokální kontrast obrazů. Zejména pokud jsou použita obrazová data reprezentována blízkými hodnotami. Díky těmto úpravám mohou být jednotlivé jasové hodnoty v histogramu lépe rozloženy. Ekvalizace histogramu může vést ke zřetelnějšímu znázornění struktur a ke zvýraznění detailů fotografií, které jsou podexponované nebo přexponované. Nevýhodou metody je to, že je nerozlišující. To znamená, že může zvětšit kontrast šumu v pozadí, zatímco se sníží užitečný signál. [9] [10]


Další úprava, která je zde uvedena, je úprava histogramu do jeho maximální dynamiky. Platí zde to samé co u ekvalizace, jen s tím rozdílem, že jednotlivé úrovně jasu zde již nemají stejnou pravděpodobnost výskytu. Příklad je ukázán na obrázku Obr. 5.30 (c)



(a)




(b)




(c)


Obr. 5.29: (a) původní vzorek nervových vláken, (b) použití ekvalizace histogramu, (c) použití plné dynamiky histogramu



(a)



(b)




(c)

Obr. 5.30: (a) histogram původního vzorku nervových vláken, (b) histogram vzorku po použití ekvalizace, (c) histogram vzorku po „roztáhnutí“ do plné dynamiky.


5.3.5 Použití Hammingova okna pro úpravu spektra

Při Fourierově transformaci konečného signálu vznikají ve spektru postraní laloky, které výrazně zkreslují skutečnou podobu spektra. Ty jsou způsobeny tím, že krajní hodnoty signálu většinou nemají stejnou velikost. Jelikož Fourierova transformace s těmito krajními hodnotami pracuje jako by mezi sebou sousedily, takže zde „vidí“ skok. Ten se poté promítne do frekvenčního spektra v podobě zmíněných postraní laloků. Ukázka takového spektra je na obrázku Obr. 5.31. Je vidět, že postraní laloky nám zcela potlačují užitečnou informaci o zkoumaném vzorku.




Obr. 5.31: Výřez frekvenčního spektra zdravého vzorku bez použití Hammingova okna.

Aby se potlačily tyto nežádoucí postraní laloky a tím se ve spektru zvýraznila užitečná informace, se používají různé typy oken, které utlumí signál na krajích. Tím zabrání rušivým přechodovým jevům. Jedním z takových oken je Hammingovo okno. Na obrázku Obr. 5.32 je vidět, že uprostřed má Hammingovo okno maximální přenos a ke stranám se zmenšuje téměř k nule. Násobením signálu tímto oknem se krajní hodnoty dostanou na stejnou úroveň a zmizí tak nežádoucí postraní laloky.



(a)





(b)



Obr. 5.32: Hammingovo okno: (a) 1D, (b) 2D

Na obrázku Obr. 5.33 je znázorněno, jakým způsobem se mění spektrum po použití Hammingova okna. U všech spekter je odfiltrována stejnosměrná složka, kde je soustředěno nejvíce energie a kvůli které by postraní laloky nebyly pouhým pohledem příliš viditelné.



Jak je vidět na prvním obrázku (Obr. 5.33 (a)), tak požadovaná informace o směru proužkové struktury je ve spektru zcela potlačena postraními laloky. Proto se použije 2D Hammingovo okno, čímž se okrajové hodnoty vzorku dostanou přibližně na stejnou hodnotu a postraní laloky se potlačí. Po jednom použití Hammingova okna se sice postraní laloky silně potlačily (Obr. 5.33 (b)), ale pořád jsou zde jasně patrné. Proto se použije Hammingovo okno ještě jednou. Na obrázku Obr. 5.33 (c) je už finální spektrum, kde jsou nežádoucí postraní laloky zcela potlačeny a zůstává pouze užitečná informace.



(a)



(b)



(c)

Obr. 5.33: Použití Hammingova okna na reálném obrázku. Vlevo vzorek nervových vláken, vpravo jeho frekvenční spektrum. (a) bez použití Hammingova okna (b) po použití jednoho Hammingova okna (c) po použití dvou Hammingových oken.

5.3.6 Testování věrohodnosti

Testování statistických hypotéz umožňuje posoudit, zda experimentálně získaná data vyhovují představám, které se díky nim získaly. Statistická hypotéza se chápe jako určitý předpoklad o rozdělení náhodných veličin. Jestliže se tyto předpoklady týkají hodnot parametrů rozdělení náhodné veličiny, hovoří se tak o parametrických hypotézách. V opačném případě se jedná o hypotézy neparametrické.

Při testování statistických hypotéz se vždy porovnávají dvě hypotézy. Jedna hypotéza, tzv. nulová (testovaná), je hypotéza, kterou testujeme. Značí se obvykle H_0 . Druhou hypotézou je tzv. alternativní hypotéza. Ta se obvykle značí H_1 .

Posuzování nulové hypotézy H_0 je založeno na následující úvaze:

- Předpokládá se, že hypotéza H_0 platí.
- Rozhodne se, kterým náhodným pokusem (například založeném na náhodném výběru) se hypotéza ověří. Určí se, která náhodná veličina bude výsledkem pokusu.
- Stanoví se hladina spolehlivosti α , neboli pravděpodobnost (míra rizika) toho, že hypotéza H_0 se neoprávněně zamítneme, ačkoliv platí. α se přitom stanovuje jako malé. Obvykle 0,05 nebo 0,01.
- V oboru možných hodnot použité náhodné veličiny se určí taková část, do níž, za platnosti H_0 , padne výsledek veličiny s pravděpodobností α . Tato část oboru možných hodnot se nazve kritický obor.
- Pokud nyní hodnota náhodné veličiny padne do kritického oboru, hypotéza se zamítá, neboť nastal jev, který by za platnosti H_0 měl jen velmi malou pravděpodobnost a jehož výskyt tudíž svědčí proti platnosti nulové hypotézy.

Výsledkem testu je rozhodnutí o nulové hypotéze. Přijetí hypotézy H_0 znamená, že se považuje za možnou. Zamítnutí hypotézy H_0 je ekvivalentní přijetí hypotézy H_1 . Testování hypotéz je tedy proces, při němž se na základě náhodného výběru rozhodne pro testovanou nebo alternativní hypotézu.

Pomocí programu Matlab se použilo dvou různých testů (vartest, t-test) pro zkoumání dat, získaných z maximálních výkonů zdravých a nemocných vzorků (Obr. 5.25 a Obr. 5.26). Tato data byly testovány proto, aby se ověřil předpokládaný rozdíl mezi hodnotami maximálních výkonů zdravých a nemocných vzorků.

Vartest zjišťuje nulovou podmínku, zda dva rozdílné vektory, v našem případě maximální výkony zdravých a nemocných vzorků, mají stejný rozptyl. Test pomocí programu Matlab tuto nulovou podmínku zamítl, tudíž jednotlivé vektory maximálních výkonů zdravých a nemocných vzorků mají rozptyl rozdílný. Z obrázků Obr. 5.25 a Obr. 5.26 se dal tento výsledek očekávat.

Druhým testem, kterým se ověřovaly maximální výkony zdravých a nemocných vzorků, byl t-test. V praxi se t-test často používá k porovnání, zda se výsledky měření jedné skupiny dat výrazně liší od výsledků druhé skupiny.

T-test je metodou matematické statiky, která umožňuje ověřit některou z následujících hypotéz:

- Zda normální rozdělení, z něhož pochází určitý náhodný výběr, má určitou konkrétní střední hodnotu, přičemž rozptyl je neznámý.
- Zda dvě normální rozdělení mající stejný (byť neznámý) rozptyl, z nichž pocházejí dva nezávislé náhodné výběry, mají stejné střední hodnoty (resp. rozdíl těchto středních hodnot je roven určitému danému číslu).

V prvním případě může být náhodný výběr tvořen buď jednotlivými hodnotami (jednovýběrový t-test), nebo dvojicemi hodnot, u nichž se zkoumají jejich rozdíly (párový t-test). Ve druhém případě jde o dvouvýběrový t-test.

Jelikož se v tomto případě zkoumají rozdíly mezi dvěma vzorky dat, použije se pro testování dvouvýběrový t-test. Ten zjišťuje nulovou podmínku, zda dva různé soubory dat mají stejnou střední hodnotu. I v tomto případě test pomocí programu Matlab tuto nulovou podmínku zamítl, z čehož vyplývá rozdílná střední hodnota pro výkony maximálních výkonů zdravých a nemocných vzorků.

Tyto testy se prováděly jak pro normální vzorky, tak i pro upravené vzorky pomocí ekvalizace histogramu a využití plné dynamiky histogramu. Výsledky testů jsou uvedeny v tabulce Tab. 5.3.

Typ testu	Vzorek bez úpravy	Po ekvalizaci histogramu	Plná dynamika histogramu
vartest	1	1	1
t-test	1	1	1

Tab. 5.3: Tabulka vyhodnocených testů, použité pro testování maximálních výkonů zdravých a nemocných vzorků. 0 značí potvrzení nulové podmínky, 1 značí její vyvrácení.

Pomocí těchto dvou testů se dokázalo, že hodnoty maximálních výkonů zdravých a nemocných vzorků mají různý rozptyl i střední hodnotu. Ač se dá z obrázků Obr. 5.25 a Obr. 5.26 vypožorovat, že jak rozptyl, tak i střední hodnota je vyšší u hodnot maximálních výkonů zdravých vzorků, testy tuto skutečnost nezkoumají.

Závěr

Tato práce se zabývá výhradně problematikou detekce vrstvy nervových vláken na sítnici. Resp. detekcí místa na sítnici, kde tato vlákna, vlivem různých faktorů, již chybí. Na začátku práce je vysvětlena samotná stavba a funkce oka. Především to, k čemu nervová vlákna na sítnici slouží a jak a proč k odumírání nervových vláken dochází. Odumíráním nervových vláken vznikají na sítnici „falešné“ slepé skvrny, což jsou místa, kde člověk není schopen přijímat světelnou informaci o okolí. Ta se následně posílá do mozku, který tuto informaci vyhodnocuje. Při méně rozšířené ztrátě nervových vláken, si je mozek s chybějící informací schopen poradit, a tak se ani často nepozná, že v určitých částech sítnice chybí nervová vlákna. Když už člověk tuto vadu, důsledkem zhoršeného vidění, pozná, bývá už často pozdě a onemocnění (především glaukom) se již nedá efektivně léčit.

Jsou zde popsány různé metody detekce vrstvy nervových vláken. Většina, převážně starších prací, které se touto problematikou zabývaly, navrhovaly různé matematické řešení, jak tyto vrstvy detekovat. U žádných řešení ale nikdy nebyla uvedena žádná praktická metoda, která by se dala jakýmkoli způsobem zrealizovat.

Možný způsob realizace detekce vrstvy nervových vláken je popsán ve studii [5]. V této práci se hledají charakteristické parametry, které jsou rozdílné pro texturu oblastí, kde jsou nervová vlákna obsažena a kde nikoli. Z této práce vyplívá, že takové parametry zcela jistě existují. Je ale velice obtížné vyhodnocovat parametry zkoumaných oblastí bez jejich manuálního nastavení. To je dáno především hustou sítí cévního řečiště, která má na výpočty nepříznivý vliv.

Dále jsou zde popsány metody detekce nervových vláken z frekvenčního hlediska. Nejprve jsou navrženy metody pro detekci proužkové struktury u umělých vzorků, které nervová vlákna simulovaly. Tyto vzorky představovaly matice proužků, které byly později i zašuměny. Jsou zde navrženy dvě detekční metody. Jsou schopny nejen detekovat proužkovou strukturu, ale i automaticky určit její směr natočení. Obě popsané metody fungují i u zašuměných matic proužků, kde šum nepřekračoval uvedenou mez poměru signál/šum (SNR). O něco lepší výsledky v detekci měla první metoda (metoda detekce proužkové struktury pomocí jejího frekvenčního spektra), která je schopna určit úhel šíření proužků při menším poměru SNR . U obou metod je však velice pravděpodobné, že různými úpravami ve výpočtu a zpracování jejich frekvenčních spekter, bude možno ještě více zmenšit poměr SNR , pro který metoda správně určí směr natočení proužkové struktury a tím i její samotnou detekci.

Další dvě popsané metody jsou již navrženy pro reálné vzorky nervových vláken. U obou se porovnávají výkony v různých oblastech frekvenčního spektra. V první metodě, popsané v kapitole 5.2, se hledaly vhodné parametry frekvenčního spektra, které by se daly použít pro samotnou detekci. Těmito parametry jsou výkony v oblastech, ve kterých se zjistil výrazný rozdíl mezi hodnotami u zdravých a nemocných vzorků. Tyto parametry se nacházejí v oblastech nízkých, nebo naopak vysokých kmitočtů. Především u vyšších kmitočtů jsou tyto parametry mezi zdravými a nemocnými vzorky znatelně odlišné. U středních frekvencí jsou výkony spektra srovnatelné pro oba druhy vzorků. Pomocí korelačního koeficientu, který zjišťoval vzájemnou korelaci mezi jednotlivými parametry se zjistilo, že na sebe mají, ve větší či menší míře, určitý vliv. Proto se dá detekce provádět pouze pomocí jednoho z nich. Nejvhodnější se zdá být parametr PP4 nebo PP5. Ty zjišťují výkon na vyšších frekvencích.

Nakonec je zde popsána detekce směru šíření nervových vláken na reálných vzorcích. Princip detekce je již o něco složitější, než u uměle navržených vzorků. Oblast vyšší energie, která má podle natočení proužkové struktury určitý směr, zaujímá širší okolí. Nestačí tedy najít pouze pozici pixelu s nejvyšší hodnotou. Nejen že by tento pixel mohl být kdekoli v dané oblasti, ale mohl by ležet i mimo ni, v nějaké daleko menší, ale energeticky třeba i výraznější oblasti. Proto se určitá část spektra rozdělila na 18 stejně velkých oblastí, ve kterých se jednotlivě počítal celkový výkon. Oblast s nejvyšším výkonem pak určuje směr šíření energie. Pokud se k získanému úhlu přičte 90° , získá se tak směr šíření nervových vláken. V tabulce Tab. 5.2 je uvedeno, jak se vypočtené úhly jednotlivých vzorků liší od úhlů, které byly ručně odhadnuty. Odchyłky jsou většinou pouze nepatrné. Hodnota maximálního výkonu se dá navíc velice dobře využít k samotné detekci proužkové struktury. Maximální výkony u zdravých vzorků totiž výrazně přesahují hodnoty těch nemocných.

Pro detekci nervových vláken je nezbytné, aby zkoumané obrázky byly co nejkvalitnější. Tzn., aby jejich rozlišovací schopnost byla co nejvyšší. Je totiž nutné, aby zkoumané vzorky neobsahovaly krevní řečiště. Proto je potřeba analyzovat co nejmenší vzorky. Na druhou stranu ale musí mít tyto vzorky co nejvíce pixelů, aby zde byla zachycena proužková struktura. Dalším kritériem je, aby snímky sítnice nebyly přexponované. Při přílišném osvětlení se totiž může stát, že některé oblasti, kde jsou zdravá nervová vlákna, mohou ztratit charakteristické proužkování. Vzorky z této oblasti by pak mohly být vyhodnoceny jako nemocné.

Seznam použité literatury

- [1] Lundström M., Eklundh J-O.: Computer sensitometru of retina nerve fibre atrophy – A pilot study, Acta Ophthalmologica, 1980
- [2] Peli E. a kol.: Computer measurements of retina nerve fibre layer strations, Applied Optics, 1989
- [3] Tamagi Y.: Correlations between atrophy of maculo-papillar bundles and visual functions in CASE of optic neuropathies, Doc. Ophthalmol. Proc. Ser., 1979
- [4] Jan J.: Číslicová filtrace, analýza a restaurace signálů, Vutium, 2002, 2:364 - 365
- [5] Kolář R., Kuběna T., Černošek P., Jan J.: Statická analýza vrstvy nervových vláken v barevných digitálních fotografiích sítnice, FEKT UBMI, VUT v Brně
- [6] Zvárová J.: Základy statistiky pro biomedicínké obory, Karolinum – nakladatelství Univerzity Karlovy, Praha, 2006
- [7] Iester M., Garway-Heath D., Lemij H.: Optic nerve head and retina nerve fibre analysis, European glaucoma society, 2006
- [8] Hycl J., Flammer J., Glaukom, Triton, 2006
- [9] Hlaváč V., Šonka M., Počítačové vidění, Grada, Praha, 1992
- [10] Jaroslavskij L., Bajla I.: Metódy a systémy číslicového spracovania obrazov, Alfa, Bratislava, 1989
- [11] Anděl J., Matematická statistika, SNTL, Praha, 1978
- [12] Fajmon B., Koláček J.: Pravděpodobnost, statistika a operační výzkum, VUT v Brně, 2005
- [13] Hořejší J., Lidské tělo, Cesty, Praha, 1996
- [14] Obrázek [on line], [cit. 2009-04-12; 10:30]. Dostupné na WWW: <http://upload.wikimedia.org/wikipedia/commons/0/02/Correlation_examples.png>.
- [15] Obrázek [on line], [cit. 2009-02.28; 21:00]. Dostupné na WWW: <<http://www.cvicime.cz/cviceni-praha/cviky/oci/stavba.html>>.